

# **REHABILITACION PARA PACIENTES POSTINFARTO CEREBRAL UTILIZANDO SISTEMAS BCI/FES**

**ALBERTO MEJIA DIEZ**

**Trabajo de grado para optar al título de  
Ingeniería Biomédica**

**Daniel Herrera Sánchez**



**UNIVERSIDAD EIA  
INGENIERIA BIOMEDICA  
ENVIGADO  
2019**

## **AGRADECIMIENTOS**

En primer lugar, me gustaría darle las gracias a mi director, Daniel Herrera, por su gran ayuda a lo largo del trabajo. A pesar de ser una persona muy ocupada por su trabajo, siempre buscaba la manera de sacar tiempo para ayudarme y resolver mis dudas. Sus conocimientos de la programación fueron una de las principales razones por la cual fue posible completar este escrito.

Le quisiera agradecer también al profesor Robinson Alberto Torres, por haber despertado en mí la pasión que siento hoy en día por la electrónica. Poder haber tenido la oportunidad de aprender de alguien que ame lo que hace y lo que enseña es un privilegio único, además su disposición y dedicación hacia sus estudiantes lo incitan a uno a querer dar siempre lo mejor de sí mismo.

Muchas gracias a Carolina Castaño por ser una increíble directora de carrera. Su apoyo facilitó mis procesos de estudio en el exterior y me permitió al mismo tiempo tener la oportunidad de aprender de la biomédica desde diferentes puntos de vista culturales.

Finalmente, le agradezco a mi familia y a la universidad EIA por haberme brindado algo tan valioso como la educación y el conocimiento.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

# CONTENIDO

	pág.
INTRODUCCIÓN.....	12
1. PRELIMINARES.....	13
1.1 Planteamiento del problema .....	13
1.2 Objetivos del proyecto .....	15
1.2.1 Objetivo General.....	15
1.2.2 Objetivos Específicos .....	15
1.3 Marco de referencia.....	16
1.3.1 Antecedentes .....	16
1.3.2 Marco Teórico .....	17
2. METODOLOGÍA.....	31
2.1 DESARROLLAR UN ALGORITMO QUE RECONOZCA PATRONES DE LA SEÑAL EEG Y ACCIONE EL DISPOSITIVO DE ESTIMULACIÓN MUSCULAR. ....	31
2.1.1 Descargar sets de señales EEG (disponibles en bases de datos de internet) 31	
2.1.2 Extraer los datos de importancia de cada set de señales en arreglos vectoriales .....	32
2.1.3 Desarrollar un algoritmo que, mediante los vectores extraídos, sea capaz de reconocer la imagen motora que produjo cada sujeto.....	33
2.2 UN SISTEMA DE ADQUISICIÓN Y PROCESAMIENTO DE LAS SEÑALES EEG HUMANAS EN TIEMPO REAL. ....	35
2.2.1 Diseño del experimento que será utilizado para obtener señales EEG.....	35
2.2.2 Adquirir señales EEG en tiempo real utilizando g.GAMMAcap .....	36
2.2.3 Probar el algoritmo diseñado para las señales de las bases de datos en las señales obtenidas por la g.GAMMAcap (hacer ajustes si se requieren).....	37

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

2.2.4	Encender y apagar un LED usando el algoritmo final .....	40
2.3	IMPLEMENTAR UN SISTEMA PARA LA ESTIMULACIÓN MUSCULAR DEL ANTEBRAZO PARA INDUCIR UN MOVIMIENTO. ....	45
2.3.1	Bosquejo del circuito de electroestimulación .....	45
2.3.2	Montar el circuito en una protoboard y hacer los ajustes necesarios hasta tener el funcionamiento deseado .....	49
2.3.3	Soldar el circuito de la protoboard en una tarjeta PCB para ahorrar espacio y un mejor desempeño. ....	50
2.3.4	Ensamblar todos los componentes electrónicos que en conjunto serán el dispositivo BCI/FES y probar funcionamiento (hacer ajustes si se requieren).....	50
3.	PRESENTACIÓN Y DISCUSIÓN DE RESULTADOS.....	53
3.1	Sesiones offline .....	53
3.1.1	Sujeto 1 .....	53
3.1.2	Sujeto 2 .....	55
3.1.3	Sujeto 3 .....	56
3.1.4	Sujeto 4 .....	58
3.2	Sesiones online .....	59
3.2.1	Sujeto 1 .....	60
3.2.2	Sujeto 2 .....	61
3.2.3	Sujeto 3 .....	61
3.2.4	Sujeto 4 .....	62
4.	CONCLUSIONES Y CONSIDERACIONES FINALES .....	63
4.1	CONCLUSIONES.....	63
4.2	CONSIDERACIONES FINALES .....	63
	REFERENCIAS .....	65

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

# LISTA DE TABLAS

	pág.
Tabla 1: Diferentes tipos de señales cerebrales: Delta, Teta, Alfa, Beta, Gamma (TBI Rehabilitation, 2018).....	21
Tabla 2: Análisis comparativo de diferentes tecnologías para la monitorización de señales cerebrales. (Morshed & Khan, 2014) .....	23
Tabla 3: Resultados de la BCI Competition 2008 (BCI Competition IV: Results, 2019)....	32
Tabla 4: Resultados de clasificación para BCI Competition IV 2a con MATLAB, Python, y OpenVibe.....	35
Tabla 5: Movimiento Real, Sujeto 1, Primera Sesión .....	53
Tabla 6: Movimiento Real, Sujeto 1, Segunda Sesión .....	54
Tabla 7: Movimiento Real, Sujeto 1, Tercera Sesión .....	54
Tabla 8: Movimiento Imaginado, Sujeto 1, Primera Sesión .....	54
Tabla 9: Movimiento Imaginado, Sujeto 1, Segunda Sesión .....	54
Tabla 10: Movimiento Imaginado, Sujeto 1, Tercera Sesión .....	55
Tabla 11: Movimiento Real, Sujeto 2, Primera Sesión .....	55
Tabla 12: Movimiento Real, Sujeto 2, Segunda Sesión.....	55
Tabla 13: Movimiento Real, Sujeto 2, Tercera Sesión .....	55
Tabla 14: Movimiento Imaginado, Sujeto 2, Primera Sesión .....	56
Tabla 15: Movimiento Imaginado, Sujeto 2, Segunda Sesión .....	56
Tabla 16: Movimiento Imaginado, Sujeto 2, Tercera Sesión .....	56
Tabla 17: Movimiento Real, Sujeto 3, Primera Sesión .....	56
Tabla 18: Movimiento Real, Sujeto 3, Segunda Sesión.....	57
Tabla 19: Movimiento Real, Sujeto 3, Tercera Sesión .....	57

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

Tabla 20: Movimiento Imaginado, Sujeto 3, Primera Sesión .....	57
Tabla 21: Movimiento Imaginado, Sujeto 3, Segunda Sesión .....	57
Tabla 22: Movimiento Imaginado, Sujeto 3, Tercera Sesión .....	57
Tabla 23: Movimiento Real, Sujeto 4, Primera Sesión .....	58
Tabla 24: Movimiento Real, Sujeto 4, Segunda Sesión.....	58
Tabla 25: Movimiento Real, Sujeto 4, Tercera Sesión .....	58
Tabla 26: Movimiento Imaginado, Sujeto 4, Primera Sesión .....	58
Tabla 27: Movimiento Imaginado, Sujeto 4, Segunda Sesión .....	59
Tabla 28: Movimiento Imaginado, Sujeto 4, Tercera Sesión .....	59
Tabla 29: Movimiento Real, Sujeto 1 .....	60
Tabla 30: Movimiento Imaginado, Sujeto 1 .....	60
Tabla 31: Movimiento Real, Sujeto 2 .....	61
Tabla 32: Movimiento Imaginado, Sujeto 2 .....	61
Tabla 33: Movimiento Real, Sujeto 3 .....	61
Tabla 34: Movimiento Imaginado, Sujeto 3 .....	62
Tabla 35: Movimiento Real, Sujeto 4 .....	62
Tabla 36: Movimiento Imaginado, Sujeto 4 .....	62

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

# LISTA DE FIGURAS

	pág.
Figura 1: Árbol de decisiones para rehabilitación de extremidades superiores después de derrame cerebral. (Hatem et al, 2016) .....	13
Figura 2: Resultados de búsqueda en PubMed para electroestimulación y rehabilitación (Takeda & Tanino & Miyasaka, 2017). .....	17
Figura 3: hemisferios cerebrales, diencefalo, mesencefalo, cerebelo, puente de Varolio, medula oblonga, medula espinal. (Kandel, Schwartz, & Jessell, 2000) .....	18
Figura 4: Mirar palabras (A), escuchar palabras (B), decir palabras (C), pensar palabras (D). (Kandel, Schwartz, & Jessell, 2000) .....	18
Figura 5: Los 4 lóbulos de la corteza cerebral. (Kandel, Schwartz, & Jessell, 2000) .....	19
Figura 6: Camino (lateral) corticoespinal descendente. (Kandel, Schwartz, & Jessell, 2000) .....	20
Figura 7: 5 tipos de ondas cerebrales: Delta, Teta, Alfa, Beta, Gamma (TBI Rehabilitation, 2018). .....	21
Figura 8: Clasificación general de los dispositivos actuales disponibles para la monitorización de señales cerebrales en tecnologías BCI. (Morshed & Khan, 2014) .....	22
Figura 9: Colocación típica de diferentes tecnologías para la monitorización de señales cerebrales. (Morshed & Khan, 2014) .....	22
Figura 10: Tipos de filtros (Nilsson & Reidel, 2005) .....	26
Figura 11: Ejemplo LDA (Li & Wang, 2014) .....	29
Figura 12: Esquema temporal del paradigma (Brunner et al, 2008). .....	31
Figura 13: Posicionamiento de los electrodos en BCI Competition 2008 (Brunner et al, 2008). .....	32
Figura 14: Diagrama de flujo para extracción y procesamiento de datos .....	34
Figura 15: Electrodo seco g.SAHARA (g.tec medical engineering, 2019) .....	36
Figura 16: g.GAMMAbox (g.tec medical engineering, 2019) .....	36

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

Figura 17: Amplificador g.USBamp (g.tec medical engineering, 2019).....	37
Figura 18: g.GAMMAcap (g.tec medical engineering, 2019) .....	37
Figura 19: Extracción de señales.....	38
Figura 20: Extracción de señales.....	39
Figura 21: Extracción de señales.....	39
Figura 22: Extracción de señales.....	40
Figura 23: Extracción de señales.....	40
Figura 24: Diagrama de flujo para extracción y procesamiento de datos (Tiempo real) ...	41
Figura 25: Posición electrodos.....	42
Figura 26: Diagrama de flujo para enviar estímulos de Python a Arduino .....	43
Figura 27: Diagrama de flujo para recibir estímulos de Python en Arduino .....	44
Figura 28: Encendido del LED. ....	45
Figura 29: Diagrama de bloques de electroestimulación (Mejia, 2017) .....	45
Figura 30: Etapa de control de frecuencia (Mejia, 2017) .....	46
Figura 31: Generación de tren de pulsos (Mejia, 2017).....	46
Figura 32: Control de tiempo en alto (Mejia, 2017) .....	47
Figura 33: conmutación de la señal (Mejia, 2017).....	47
Figura 34: Aumento de tensión de la señal (Mejia, 2017) .....	48
Figura 35: Control de intensidad (Mejia, 2017) .....	48
Figura 36: Prototipo final (protoboard) .....	49
Figura 37: Tren de pulsos (Mejia, 2017) .....	49
Figura 38: Electroestimulador en tarjeta PCB .....	50
Figura 39: Arduino Uno (Arduino, s.f).....	50
Figura 40: Arduino Uno (Arduino, s.f).....	51

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.



Figura 41: Conexión pines Arduino .....	51
Figura 42: Electroestimulador versión final .....	52
Figura 43: Contracción controlada por señal EEG .....	60

## RESUMEN

Acorde al artículo “Stroke: A global response is needed”, a nivel mundial, los accidentes cerebrovasculares son la segunda causa de muerte y la tercera causa de discapacidad en personas (Johnson et al, 2016).

Algunas de las complicaciones que pueden experimentar las personas que han sufrido de derrame cerebral, listadas por la Clínica Mayo, incluyen parálisis o pérdida de movimientos musculares, dificultad en el habla o tragar, pérdida de memoria o dificultad para pensar, problemas emocionales, dolores severos y cambios en comportamiento y la habilidad de cuidado personal (Mayo Clinic, 2018).

Actualmente los métodos de rehabilitación disponibles se ven limitados por el hecho de que poseen un corto alcance para una población de personas afectadas tan grande. Dichos métodos solo logran brindar resultados considerablemente notables a aquellas personas que han sufrido daños leves en sus funciones motoras. En el estudio realizado por Dobkins se comprobó que solo un 25% de las personas que sufren de derrame cerebral son capaces de eventualmente retomar una vida diaria similar a la de una persona saludable (Dobkins, 2005).

Hasta ahora, el mercado ya ofrece dispositivos de electroestimulación para la rehabilitación de funciones motoras utilizando señales de electromiografía (señales eléctricas que se dan nivel muscular) como el NESS H200. Las personas que han sufrido daños leves son capaces de accionarlos debido a que la mayoría todavía son capaces de generar impulsos eléctricos lo suficiente fuertes para ser detectados por dispositivos de electromiografía (EMG) pero sin embargo muy débiles para superar el potencial de acción necesario para contraer el músculo.

Por esta razón surge la necesidad de desarrollar un dispositivo que trabaje bajo el mismo concepto de electroestimulación previamente mencionado pero que no sea dependiente del funcionamiento motor residual del paciente y así mismo se lograra aumentar el alcance a personas con daños más severos de su sistema nervioso.

Una interfaz cerebro maquina (BCI por sus siglas en inglés) permite identificar señales cerebrales específicas y convertirlas en una serie de comandos digitales para controlar un dispositivo externo. Dichas señales cerebrales pueden obtenerse de numerosas maneras, una de ellas siendo a través de equipos de electroencefalografía (EEG). Una vez obtenidas las señales, estas son clasificadas mediante un algoritmo computacional para posteriormente expresarlas como impulsos eléctricos para poder inducir contracciones en el músculo.

Considerando el hecho que las señales cerebrales generadas cuando se imagina un movimiento (imagen motora o MI por sus siglas en inglés) son muy similares a las que se generan cuando se lleva a cabo tal movimiento, la activación del dispositivo de electroestimulación no se verá afectada por la capacidad motora residual que presente el paciente afectado.

**Palabras Clave:** MI, EEG, BCI, electroestimulación, derrame cerebral.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

# ABSTRACT

According to the article "Stroke: A global response is needed", at a worldwide level, brain strokes are the second cause of death and the third cause of disability on people (Johnson et al, 2016).

Some of the complications that people who have suffered brain stroke can experience, listed by the Mayo Clinic, include paralysis or loss of muscle movement, difficulty speaking or swallowing, loss of memory or difficulty thinking, emotional problems, severe pain or changes in behavior and the ability of selfcare (Mayo Clinic, 2018).

The methods of rehabilitation available right now are limited by the fact that they possess a short populational reach compared to the large amount of people who are affected by it. Such methods only manage to provide considerable results to those people who have suffered mild damages in their motor functions. In a study carried out by Dobkins, it was shown that only a 25% of the people who suffered from brain stroke were capable of eventually returning to an everyday life similar to the one of a healthy person (Dobkins, 2005).

Currently, the market already offers devices of electrostimulation for the rehabilitation of motor functions using electromyography signals (electrical signals that result from muscle contractions) like the NESS H200. The people who have suffered from mild cerebral damages are able to activate this device due to the fact that most of them are still able to generate electrical impulses strong enough to be detected by electromyography (EMG) but not strong enough to surpass the action potential threshold needed to contract the muscle.

For this reason, the necessity to develop a device that works under the same concept of electrostimulation mentioned previously but is not dependent on the residual motor functioning of the patient arises, and this way directly increasing the amount of people with more severe damages to their nervous system who can benefit from it.

A brain computer interface (BCI) allows the user to control an external device by identifying specific brain signals and converting them into a series of digital commands. Such signals can be obtained by numerous ways, one of them being through electroencephalography (EEG) equipment. Once those signals are obtained, they are classified using a computational algorithm so that they can be further on expressed as electrical impulses in order to induce muscle contractions.

Considering the fact that the brain signals generated when a motor movement is imagined (MI or motor imagery) are very similar to the signals generated when the actual movement is carried out, the activation of the electrostimulation device will not be affected by the residual motor capacity present on the affected patient.

**Keywords:** MI, EEG, BCI, electrostimulation, brain stroke

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

## INTRODUCCIÓN

El derrame cerebral sucede cuando se detiene el flujo sanguíneo al cerebro. Es por esta razón que en solo cuestión de minutos comienzan a morir las células cerebrales. Existen dos tipos de derrames cerebrales: El más común, conocido como derrame cerebral isquémico, sucede cuando se forma un coagulo de sangre en un vaso sanguíneo del cerebro. El segundo, conocido como derrame cerebral hemorrágico, es debido a la ruptura de uno de los vasos sanguíneos del cerebro (Biblioteca Nacional de Medicina [NLM], s.f.).

Ambos tipos conllevan a un déficit de perfusión de sangre disminuyendo la oxigenación de la zona del cerebro afectada. El resultado, muerte del tejido cerebral lo cual puede implicar una reducción considerable en la capacidad neuromotora de la persona.

Según Feigin, durante el periodo de 1990-2013 se registraron alrededor de 25.7 millones de casos de personas, a nivel mundial, que habían sufrido algún tipo de derrame cerebral y sobrevivieron, y otros 6.5 millones habían muerto (Feigin et al ,2015). Además, solo en ese último año hubo cerca de 10.3 millones de casos nuevos de derrame cerebral. Es por esta razón que, después de enfermedades cardíacas, se ha establecido como uno de los mayores causantes de discapacidad, afectando su movilidad y disminuyendo la posibilidad de reintegrarse en su vida profesional.

Tomando esto en consideración, y el hecho de que la cantidad de personas afectadas esta incrementado, es válido decir que los métodos convencionales de prevención y rehabilitación generan un impacto positivo, pero se puede abordar nuevas soluciones que complementen los métodos actuales para abarcar de forma positiva a más personas.

Con el propósito de brindar una solución a estas complicaciones, específicamente parálisis o perdida de movimientos musculares, y facilitar una alternativa que permita reintegrar estas personas a su estilo de vida habitual, el presente proyecto se enfocará en el desarrollo de un dispositivo que incorpore los avances tecnológicos que hay hasta el momento, tanto de sistemas BCI, como de electroestimulación funcional (FES por sus siglas en inglés).

El trabajo se encuentra dividido en cuatro componentes principales: Preliminares, donde se formula el problema y se justifica la necesidad de llevar a cabo la investigación efectuada en este trabajo, los objetivos propuestos para solucionar el problema, un análisis detallado del estado del arte con respecto a la solución propuesta, y una contextualización básica de los diferentes temas que serán mencionados a lo largo de la tesis; Metodología, describe los pasos que se siguieron para cumplir cada uno de los objetivos; Presentación y discusión de resultados, suministra datos concretos de los experimentos llevados a cabo; Conclusión y consideraciones finales, habla finalmente de la viabilidad de poner a disposición de los pacientes el dispositivo, teniendo en cuenta cosas como el impacto social, costos de producción, facilidad de uso para los pacientes, sostenibilidad, etc.

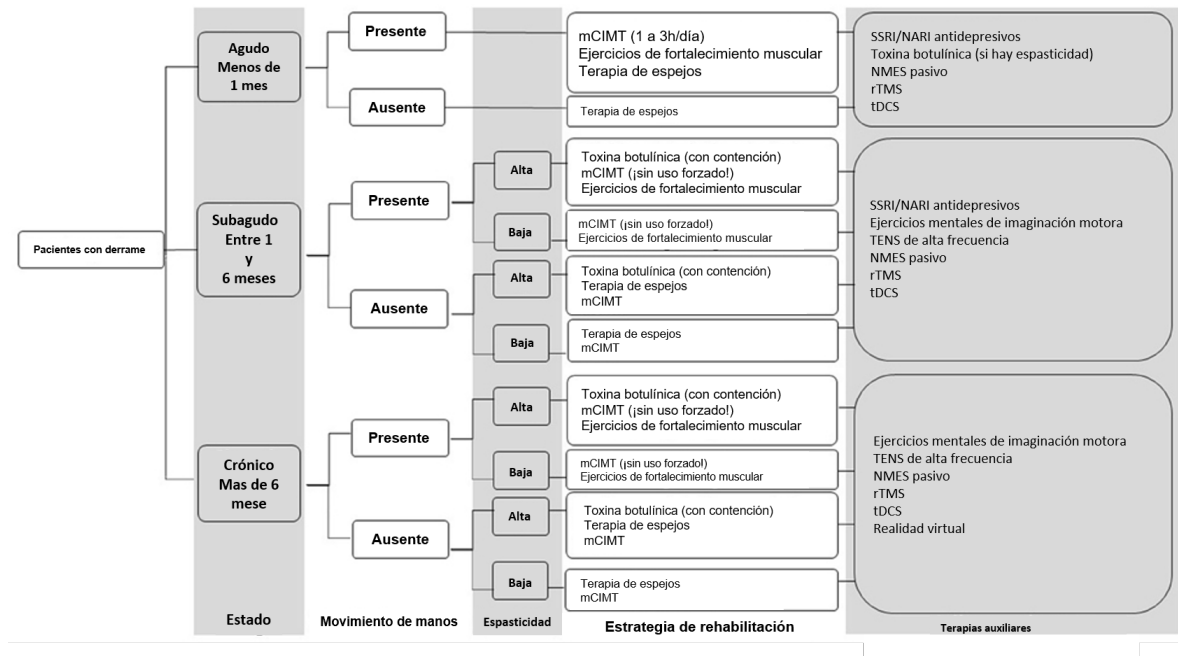
La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

# 1. PRELIMINARES

## 1.1 PLANTEAMIENTO DEL PROBLEMA

Según Feigin, durante el periodo de 1990-2013 se registraron alrededor de 25.7 millones de casos de personas, a nivel mundial, que habían sufrido algún tipo de derrame cerebral y sobrevivieron, y otros 6.5 millones habían muerto (Feigin et al, 2015). Además, solo en ese último año hubo cerca de 10.3 millones de casos nuevos de derrame cerebral. Es por esta razón que, después de enfermedades cardíacas, se ha establecido como uno de los mayores causantes de discapacidad.

Tomando esto en consideración, y el hecho de que la cantidad de personas afectadas esta incrementado, es válido decir que los métodos convencionales de prevención y rehabilitación generan un impacto positivo, pero se puede abordar nuevas soluciones que complementen los métodos actuales para abarcar de forma positiva a más personas.



**Figura 1:** Árbol de decisiones para rehabilitación de extremidades superiores después de derrame cerebral. (Hattem et al, 2016)

La figura 1 muestra posibles combinaciones de tratamientos, que se pueden ejercer dependiendo de diversos factores como: El estado del paciente (Agudo, subagudo, y crónico), si hay o no capacidad motora, y el nivel de espasticidad. En aquellos casos donde la movilidad del paciente esta reducida, las únicas soluciones propuestas son terapia de movimiento inducido por restricción y terapia con espejos. La terapia de movimiento inducido por restricción obliga al paciente a

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

esforzarse a usar el miembro parético de manera intensiva, restringiendo el movimiento del miembro no parético. La terapia con espejos, como su nombre lo dice, consiste en ubicar un espejo en el plano sagital medio del paciente reflejando de esta manera los movimientos hechos por el lado no parético y así mismo creando la ilusión óptica de que se está realizando un movimiento normal en el lado parético.

No obstante, el factor de que solo hay dos tipos de estrategias de rehabilitación para personas cuya capacidad motora es nula indica la poca flexibilidad que tienen los tratamientos para acogerse a las necesidades de las personas. Siendo potencialmente una de las razones más significativas por las cuales los métodos convencionales no son suficientes.

Vale aclarar que la imagen presentada anteriormente también introduce la posibilidad de utilizar técnicas auxiliares. Se propone: El uso de ejercicios mentales de imaginación motora, un amplio grupo del cual haría parte terapia con espejos y realidad virtual; NMES pasivo (electroestimulación neuromuscular por sus siglas en inglés), acoge dentro de su categoría a TENS (Electroestimulación nerviosa transcutánea por sus siglas en inglés) y varios otros tipos de electroestimulación; rTMS (estimulación transcraneal magnética repetitiva) usando un campo magnético es posible inducir la despolarización o hiperpolarización de las neuronas gracias a que estas trabajan a su vez mediante impulsos eléctricos logrando así controlar su excitabilidad; tDCS (estimulación transcraneal de corriente directa por sus siglas en inglés) es similar a rTMS pero la estimulación se aplica mediante una corriente directa usando electrodos ubicados sobre el cráneo, no obstante el propósito es el mismo, aumentar o disminuir la excitabilidad de las neuronas. TENS y Realidad Virtual son las más relacionadas con el trabajo, razón por la cual serán explicadas a mayor profundidad a continuación. rTMS y tDCS han sido descartadas como opciones para este estudio por el hecho que rTMS requiere un equipo considerablemente grande y costoso lo que lo hace menos accesible, mientras que tDCS existe el riesgo de que el paciente sufran convulsiones y los estudios realizados en el tema aun no son concluyentes.

La electroestimulación muscular puede ser inducida cambiando el tipo de onda (monofásica, bifásica, polifásica) y/o la intensidad, entre otras cosas (Takeda, Tanino, & Miyasaka, 2017). TENS toma en consideración estas variables para que aliviar el dolor muscular causado generalmente por espasticidad. Viendo que su capacidad se ve limitada normalmente a aliviar dolor muscular, su alcance de rehabilitación suele ser corto. FES (otro tipo de NMES), a diferencia de TENS, tiene la característica de que puede hacer que las contracciones musculares que causa sean expresadas en movimientos funcionales, siendo más llamativo para el tema de rehabilitación neurológica.

Las señales cerebrales más adecuadas para este estudio son conocidas como ritmos sensoriomotores (SMRs por sus siglas en inglés) debido a que son moduladas por intenciones motoras, en otras palabras, son generadas cuando una persona realiza un movimiento o produce una imagen mental del movimiento que desee llevar a cabo. Con base a Zapala, se puede ver el valor agregado de la retroalimentación visual a la hora de entrenar al paciente a modular los SMRs (Zapala et al, 2018). La rehabilitación mediante Realidad Virtual al igual que la terapia de espejos trabajan bajo este concepto, el uso de ejercicios mentales de imaginación motora. La diferencia yace en que la Realidad Virtual, al ser controlada por los SMRS del paciente con un dispositivo de EEG, le da la sensación de que ha recuperado su movimiento mientras se encuentra en este mundo virtual. Esto resulta ser un factor de importancia, ya que el proceso de rehabilitación es importante que el paciente disfrute lo que hace para que este imponga una actitud más proactiva. A pesar de ello, este método carece de retroalimentación muscular, una con la cual el paciente pueda en realidad ocasionar el movimiento físico que le está enseñado a su cerebro a modular.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

Rossini, en resumen, dice que la neuroplasticidad es la habilidad del cerebro para readaptarse y evolucionar a estímulos externos. Aquellos estímulos que son capaces de inducir un cambio en la plasticidad cerebral son de naturaleza fisiológica o patológica. Estos cambios pueden ser buenos, como mejorarse de una lesión (plasticidad restaurativa) o malos, como realizar movimientos anormales para compensar la pérdida de movilidad que se produjo por la lesión (plasticidad aberrante) (Rossini et al, 2012).

Es posible concluir del párrafo anterior dos cosas: Si los estímulos son lo que ocasionan cambios en la plasticidad cerebral, el uso en conjunto de diferentes estímulos puede tener un mayor efecto. De este supuesto parte la propuesta de en vez de utilizar técnicas como ejercicios mentales de imaginación motora y NMES por separado, aplicarlos en conjunto para obtener un mejor resultado; Varios de los equipos que utilizan EEG para controlar dispositivos virtuales, electrónicos, o mecánicos, pueden ser contraproducentes ya que esto puede causar que se generen caminos neuronales inadecuados en ciertas personas, impidiéndoles en un futuro lograr una recuperación optima si no se implementan adecuadamente.

En el artículo “An adaptive CSP filter to investigate user Independence in a 3-class MI-BCI paradigm” (Costa, Møller, Iversen & Puthusserypady, 2018) hablan de que hay una variabilidad intra-sujetos e inter-sujetos en la neuro plasticidad cerebral después del derrame cerebral y durante sus periodos de recuperación, haciendo énfasis en la necesidad de un sistema que cumpla las necesidades de cada paciente. La solución, usar un filtro adaptivo (ACSP) sobre señales de EEG obtenidas, lo que permitiría brindar la realimentación visual, auditiva y/o física correcta. Saber si la tarea mental que se encuentran ejecutando si es la apropiada podría entonces guiar la formación de nuevos caminos neuronales en la dirección adecuada desde el principio del proceso de rehabilitación. Aunque esta solución prueba tener buenos resultados sin la necesidad de usar una gran cantidad de muestras e incorpora BCI como estrategia alternativa de rehabilitación, es un sistema que debe ser supervisado por una persona para encontrar la convergencia entre la cantidad de ensayos y los hiper-parametros más apropiados, descartando la opción de poder ser implementado en un dispositivo portátil en algún futuro.

Pero entonces surge la pregunta: ¿Qué métodos de procesamiento lograrían clasificar con precisión las señales EEG obtenidas a través de filtros CSP (patrón común espacial por sus siglas en inglés) logrando un sistema BCI/FES que ofrezca un menor tiempo de recuperación a comparación de los ejercicios de rehabilitación de hoy en día?

## **1.2 OBJETIVOS DEL PROYECTO**

### **1.2.1 Objetivo General**

Desarrollar un dispositivo electrónico que use señales sensoriomotoras para estimular las terminales nerviosas de los músculos del antebrazo a través de una BCI que acciona FES.

### **1.2.2 Objetivos Específicos**

- Desarrollar un algoritmo que reconozca patrones de la señal EEG y accione el dispositivo de estimulación muscular.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

- Implementar un sistema de adquisición y procesamiento de las señales EEG humanas en tiempo real.
- Implementar un sistema para la estimulación muscular del antebrazo para inducir un movimiento.

### 1.3 MARCO DE REFERENCIA

#### 1.3.1 Antecedentes

##### ○ BCI

El concepto de BCI surgió poco después de que Hans Berger realizo la primera medición de ondas cerebrales en humanos, alrededor de 1929, con un equipo de electroencefalografía. Desde ese momento la gente empezó a especular que estas señales podrían ser usadas como un medio de comunicación y control de dispositivos externos. (Wolpaw et al, 2000).

En 1973, Jean Jacques Vidal publicó un artículo ("Toward direct brain-computer communication") en el cual daba un paradigma de los pasos a seguir para llevar a cabo un experimento de medición de señales EEG y preprocesado adecuado para posteriormente usar estas señales como comandos entre una interfaz cerebro máquina.

Vale aclarar que se requiere invertir entre 10 y 20 sesiones de entrenamiento en modulación de señales cerebrales para controlar adecuadamente una BCI según Teo y Chew (Teo & Chew, 2014). Aun así, las sesiones de entrenamiento sirven igualmente para el proceso de mejora del paciente solo que este ha probado mostrar mejores resultados cuando es combinando con electroestimulación de los músculos y hasta hay veces usando un brazo robótico para asistir el movimiento. Es la suma de todos estos dispositivos que cada vez logra acortar más el tiempo de mejora de los pacientes.

##### ○ FES

Normalmente, la contracción muscular es producida por impulsos electroquímicos generados en el sistema nervioso central y se transmiten en una especie de efecto domino por el sistema nervioso periférico hasta el musculo que se desea contraer. FES consiste en generar dicha contracción de manera indirecta aplicando una corriente eléctrica externa sobre el musculo induciendo un resultado similar a cuando se genera el impulso desde el sistema nervioso central (Manske et al, 2016).


Existen dos tipos de electroestimulación: "Denominando estática cuando se realiza la técnica sin movilidad articular, es decir, la activación muscular no provocará movimiento articular y dinámica cuando la técnica se combina con movilidad articular provocada por la activación del grupo muscular estimulado." (García, 2001). En este proyecto se trabajará con electroestimulación dinámica, para lograr esto el estimulador genera microchoques eléctricos de manera repetitiva logrando algo similar a una contracción muscular voluntaria.

La figura 2 muestra como ha incrementado el número de búsquedas en PubMed para: ("electroestimulación" O "electroestimulación muscular" O "electroestimulación nerviosa" O FES O

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.



NMES) Y (derrame cerebral O “enfermedad cerebrovascular” O hemiplejía O hemiparético O hemiparesia O parálisis O rehabilitación).



**Figura 2:** Resultados de búsqueda en PubMed para electroestimulación y rehabilitación (Takeda & Tanino & Miyasaka, 2017).

Hay un incremento exponencial en la cantidad de estudios que se han venido realizando hasta el momento con respecto al uso de electroestimulación para la rehabilitación de pacientes con derrame cerebral. Resumiendo lo que dijo Popovic la estimulación eléctrica funcional (FES) fue un método introducido para artificialmente activar el sistema sensoriomotor tras una lesión en el sistema nervioso central (Popovic, 2014).

Mejia, graduada de la universidad EIA, elaboro un estudio de un sistema para electroestimulación y comprobó que la manera más adecuada de conseguir la contracción dinámica del musculo es a través de un tren de impulsos eléctricos (Mejia, 2017).


Además, Yan y compañía, realizaron un estudio en el que 46 sujetos de prueba con derrame cerebral eran separados en 3 grupos para estudiar la viabilidad del uso de FES en la recuperación de habilidad motora en extremidades inferiores. Un grupo recibía rehabilitación FES, otro grupo de placebo, y un grupo de control. Las personas asignadas al grupo de rehabilitación mediante el uso de FES fueron todas capaces de caminar después del tratamiento y el 84.6% de ellos fueron dados de alta para volver a casa a diferencia del grupo placebo (53.3%) y el grupo de control (46.2%) (Yan & Hui-Chan & Li, 2005).

### 1.3.2 Marco Teórico

#### ○ Sistema Nervioso Central

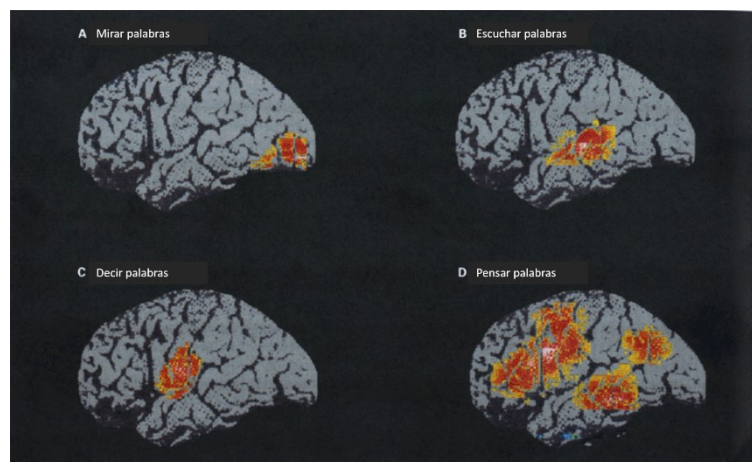
El sistema nervioso central está separado en siete partes principales como se puede ver en la Figura 3. Cada una juega un papel importante en la ejecución de las operaciones efectuadas por el cerebro.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.



**Figura 3:** hemisferios cerebrales, diencefalo, mesencéfalo, cerebelo, puente de Varolio, medula oblonga, medula espinal. (Kandel, Schwartz, & Jessell, 2000)


A través de varios estudios médicos ha sido posible identificar qué zonas del cerebro se ven involucradas en llevar a cabo diferentes tareas motoras. Un ejemplo de esto puede ser visto en la Figura 4, en la cual utilizaron tomografía por emisión de positrones (PET) para identificar las zonas del cerebro implicadas en 4 diferentes tareas que tenía que realizar el paciente siendo analizado.



**Figura 4:** Mirar palabras (A), escuchar palabras (B), decir palabras (C), pensar palabras (D). (Kandel, Schwartz, & Jessell, 2000)

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

**Hemisferios Cerebrales:** Compuesto por una capa exterior conocida como la corteza cerebral dentro de la cual yacen el ganglio basal (Regula las funciones motoras), el hipocampo (Almacenamiento de memoria), y los núcleos amigdaloides (Coordinan la respuesta autonómica y endocrina del estado emocional). Además de esto, la corteza cerebral se encuentra subdividida en 4 lóbulos. El lóbulo frontal se encarga de planear acciones futuras y controlar el movimiento. El lóbulo parietal de sensaciones somáticas, formación de imágenes corporales, y relacionar la imagen corporal propia con el espacio extra-personal percibido. El lóbulo occipital de la visión. Finalmente, el lóbulo temporal de la escucha. En la Figura 5 muestra la ubicación de cada uno de los lóbulos. (Kandel, Schwartz, & Jessell, 2000).



**Figura 5:** Los 4 lóbulos de la corteza cerebral. (Kandel, Schwartz, & Jessell, 2000)

**Diencefalo:** Contiene el tálamo, el cual procesa la mayoría de la información que llega a la corteza cerebral y al resto del sistema nervioso, y el hipotálamo, que regula respuestas autonómicas endocrinas y funciones viscerales.

**Mesencéfalo:** Controla varias de las funciones motoras y sensoriales, incluyendo movimiento de los ojos, coordinación visual y reflejos auditivos.

**Cerebelo:** Modula la fuerza y el rango de movimientos, además está involucrado en el aprendizaje de habilidades motoras.


**Puente de Varolio:** Transmite información, relacionada al movimiento, desde los hemisferios cerebrales hacia el cerebelo.

**Medula oblonga:** Regula algunas de las funciones autonómicas vitales (respirar, digestión, ritmo cardíaco, etc.)

**Medula espinal:** Recibe y procesa información sensorial del cuerpo y transmite información motora a los músculos de las extremidades. Subdividida en el cérvico, tórax y el sacro.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

La figura 6 muestra el camino corticoespinal (compuesto por cada una de las partes descritas anteriormente) que debe recorrer una señal para que se pueda efectuar una acción motora, en este caso la acción motora que se está realizando en la imagen consiste en tocar el piano.



**Figura 6:** Camino (lateral) corticoespinal descendente. (Kandel, Schwartz, & Jessell, 2000)

Es posible darse cuenta de que cualquier daño ocasionado a la corteza cerebral puede interrumpir el flujo de información a las extremidades controladas por dicha zona. Derivando de este factor viene el supuesto del proyecto, con electroestimulación funcional, lograr generar un campo eléctrico pulsátil que active la contracción muscular deseada similar a como lo haría una señal eferente del SNC (sistema nervioso central) cuando induce un potencial de acción en el musculo para causar una contracción voluntaria. La diferencia consiste en que la estimulación eléctrica del musculo provendrá de señales cerebrales de las zonas no afectadas y viajará por un dispositivo extracorpóreo, evitando el problema en los daños de los caminos habituales recorridos para generar dicha contracción consiguiendo así un resultado similar a antes de que sucediera el derrame. De esta manera, y gracias a la neuro plasticidad del cerebro será posible establecer nuevos caminos neuronales que eventualmente reemplazarán los caminos dañados por la lesión cerebral hasta el punto en el que el uso del dispositivo no siga siendo requerido.


La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

○ **Señales Cerebrales**

Nuestro cerebro produce principalmente 5 diferentes tipos de ondas. La tabla 2 indica del rango de frecuencia en el que opera cada una además de la función primaria con la que cumple. La figura 7, tiene como propósito dar una idea al lector de la forma de onda de cada una de estas señales.

Frecuencia	Nombre:	Normalmente asociadas con:
>40 Hz	Ondas gamma	Alta actividad mental (percepción, solución de problemas y la conciencia)
13-39 Hz	Ondas beta	Pensar, procesar ideas, concentrarse, estar alerta, cognición.
7-13 Hz	Ondas alfa	Tranquilidad y relajación
4-7 Hz	Ondas teta	Meditación profunda/relajación, sueños REM.
<4 Hz	Ondas delta	Sueño profundo, pérdida de percepción del cuerpo.

**Tabla 1:** Diferentes tipos de señales cerebrales: Delta, Teta, Alfa, Beta, Gamma (TBI Rehabilitation, 2018).

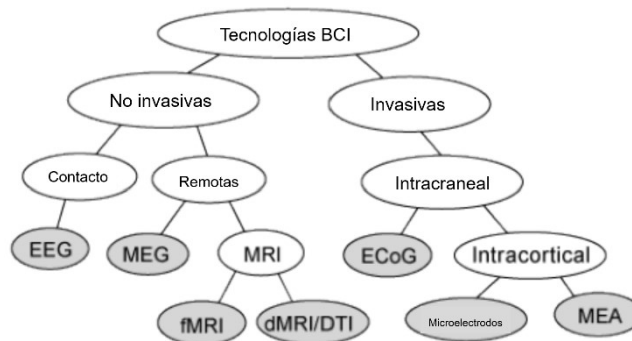


**Figura 7:** 5 tipos de ondas cerebrales: Delta, Teta, Alfa, Beta, Gamma (TBI Rehabilitation, 2018).


La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

Como se dijo anteriormente, los estudios realizados a lo largo del presente escrito serán basados en el análisis de SMRs ya que estos ocurren el momento que una persona lleva a cabo una intención motora. “Es posible distinguir este suceso debido a que se manifiesta un decremento en la amplitud de las bandas de frecuencia alfa (ritmos mu) y beta, acompañado de un incremento en la amplitud de la banda de frecuencia gamma. Cambios en la amplitud de la señal EEG están directamente relacionados con el número de neuronas activándose en un momento específico, mayor cantidad de neuronas sincronizadas equivale a mayor amplitud y viceversa. Este fenómeno se le conoce como ERD (desincronización relacionada a un evento por sus siglas en inglés) y ERS (sincronización relacionada a un evento por sus siglas en inglés). (Yuan & He, 2014). Lo que indica que mirando la amplitud de la señal en diferentes bandas de frecuencia en las zonas del cerebro activas (específicamente la corteza prefrontal motora) permitiría identificar el momento que ocurren estos sucesos.

Las señales cerebrales se pueden obtener de numerosas maneras. Algunos de los tipos de monitorización utilizados en tecnologías BCI aparecen en la figura 8. La siguiente ilustración, figura 9, muestra la ubicación de cada una de estas tecnologías con respecto a cabeza de un ser humano.



**Figura 8:** Clasificación general de los dispositivos actuales disponibles para la monitorización de señales cerebrales en tecnologías BCI. (Morshed & Khan, 2014).



**Figura 9:** Colocación típica de diferentes tecnologías para la monitorización de señales cerebrales. (Morshed & Khan, 2014)

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

Finalmente, la tabla 2 que se muestra a continuación menciona algunas de las propiedades de cada uno de estos métodos de monitorización juntos con sus ventajas y desventajas.

Tecnologías	Actividad física subyacente	Ubicación	Rango de frecuencia	Amplitud de señal	Resolución espacial	Resolución temporal	Ventajas claves	Desventajas claves
EEG	Actividad neuronal sincrónica (potencial de acción)	Contacto con el pericráneo (usualmente con un casco)	0.1-100 Hz	Menos de 100 $\mu$ V	1cm	1-5 ms	No invasivo, portátil	Resolución espacial baja
MEG	Actividad neuronal sincrónica (corriente)	Remoto (ej. Casco)	2-100 Hz	Menos de 10-12 Tesla	2-3 cm	~1 ms	No invasivo	No es portátil
MRI	Aumento del flujo sanguíneo en los lóbulos corticales	Remoto (cama dentro de un equipo tubular)	-	-	1-10 mm	1-2 s	No invasivo, no hay contacto	No es portátil, resolución temporal baja
ECoG	Potencial de campo local	Intracraneal, superficie cortical	1-100 Hz	Algunos cientos de $\mu$ V	0.5-3 mm	~1 ms	Buena calidad de la señal, resolución espacial y temporal alta	Requiere cirugía, altamente invasivo
Microelectrodos	Potencial de acción extracelular	Intracraneal, intracortical	0.5-5 KHz	Unos pocos mV	~100 $\mu$ m <sup>2</sup>	0.1 ms	Buena calidad de la señal, resolución espacial y temporal alta	Cirugía de alto riesgo requerida, gliosis y otras complicaciones medicas
MEA	Actividad neuronal extracelular de múltiples zonas del cerebro	Intracraneal, intracortical	0.5-5 KHz	Unos pocos mV	~100 $\mu$ m <sup>2</sup> en cada zona	0.1 ms	Buena calidad de la señal, monitorización simultanea de varias zonas	Cirugía de alto riesgo requerida, gliosis y otras complicaciones medicas

**Tabla 2:** Análisis comparativo de diferentes tecnologías para la monitorización de señales cerebrales. (Morshed & Khan, 2014)

Con base a las ilustraciones exhibidas anteriormente se decidió optar por el uso de equipos EEG por su simplicidad, portabilidad, costo, y el hecho de que no son invasivos facilita enormemente realizar mediciones en numerosas personas sin la implicación de llevar acabo preparaciones muy rigurosas.

## ○ EEG

Con base a los datos exhibidos en el punto anterior y considerando su amplio campo de aplicaciones (psicología, medicina, neurociencia, e incluso videojuegos), hay varias compañías que se encuentran trabajando en el desarrollo y producción de dispositivos de EEG. Su propósito es

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.



que cualquier persona puede tener fácil acceso a las herramientas necesarias para tener su propio dispositivo de EEG adecuado a las necesidades específicas de cada usuario. Estas pueden variar con respecto al número de canales, portabilidad, métricas predefinidas, y precio (Farnsworth, 2019). A continuación, se mostrarán algunos de los dispositivos disponibles hasta el momento en el mercado distribuidos en tres diferentes rangos de precios (bajo, medio, alto) junto con algunas de las especificaciones que definen porque valen lo que valen.

**Rangos de precio bajos (\$99-\$1000):** Cuentan con una cantidad mínima de electrodos y son principalmente usados para investigar soluciones que puedan mejorar la meditación y el sueño.

- NeuroSky (1 canal)
- Muse (4 canales)
- Emotiv (14 canales)
- OpenBCI (8-16 canales)

**Rangos de precio medio (\$1000-\$25,000):** Disponen de una mayor cantidad de electrodos y son todos de propósito investigativo. Proveen métricas de mayor precisión, facilitando una introspección mas valiosa sobre el material adquirido de las señales.

- Wearable Sensing (7-24 canales)
- ANT Neuro: eego rt / eego sports (8-32 canales)
- Neuroelectronics (8-32 canales)
- G.tec (8-64 canales)
- ABM B-Alert (10-20 canales)
- BioSemi (16 canales)
- Cognionics (20-30 canales)
- mBrainTrain (24 canales)
- Brain Product LiveAmp (32 canales)

**Rangos de precio medio (\$25,000+):** Equipados con una gran cantidad de electrodos para proporcionar una alta resolución en el momento de detectar las señales. Son lo mejor que dispone el mercado, sin embargo, el tipo de investigación es la que define la resolución necesaria por lo que en muchos casos bastaría con los dispositivos del rango de precio bajo y medio para suplir las necesidades del usuario.

- ANT Neuro: eego rt / eego sports (64 canales)
- ANT Neuro: eego mylab (32-256 canales)

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.



- Brain Products ActiCHamp (32-160 canales)
- BioSemi (32-256 canales)

## ○ **Software**

Existe una gran variedad de softwares para el procesamiento de datos. Al igual que con los dispositivos de EEG, el usuario puede preferir uno sobre otro dependiendo de sus necesidades.

MATLAB posee la ventaja de ser un programa disponible a través de una licencia estudiantil que dispone la universidad, no afectando el costo final del dispositivo. Estudiantes de la universidad VIT en India ya han hecho ensayos con MATLAB para el procesamiento de señales EEG por su flexibilidad e interfaz gráfica interactiva orientada a matrices numéricas. (Gurumurthy et al, 2013)

Python a diferencia de MATLAB es un lenguaje de programación de propósito general. Sin embargo, es muy adaptable a las necesidades del programador por la cantidad de librerías adicionales que se le puede descargar. Además, posee la ventaja de que sus algoritmos pueden ser utilizados en ordenadores de placa reducida.

La Universidad EIA en convenio con la Universidad CES realizó un estudio sobre el tema de interfaz cerebro computador en el cual el procesamiento de la señal fue hecho con un software específico para la tarea llamado BCI2000 ya que podía ayudar a entrenar a la maquina a reconocer señales en tiempo real con mayor facilidad (López & Pabón, 2013).

LabVIEW está enfocado a la programación grafica con el fin de facilitar la interacción del usuario con la interfaz. Esto permite que personas que no tengan fundamentos claros en algún lenguaje de programación puedan también desarrollar algoritmos de análisis de datos y diseñar interfaces de usuarios personalizadas con facilidad. Al mismo tiempo el software de LabVIEW tiene la ventaja de que es compatible con equipos hardware de distintitos proveedores (National Instruments, s.f).

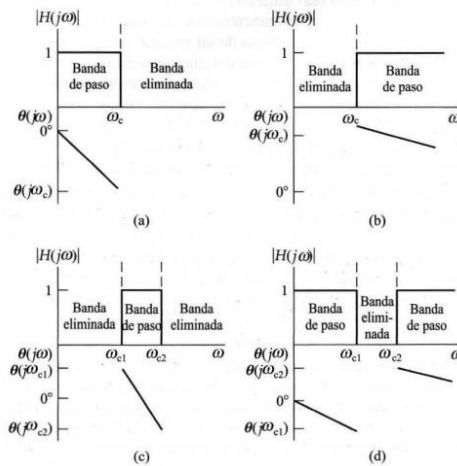
OpenVibe es una plataforma de software gratis diseñada específicamente al desarrollo, diseño y testeo de BCI. Su mayor cualidad es que permite adquirir, filtrar, procesar, clasificar y visualizar las señales cerebrales en tiempo real. Además de esto posee varios ejemplos de programas que han sido elaborados por diferentes contribuidores para darle una idea básica a los usuarios de como comenzar a desarrollar su propia BCI. Al igual que LabVIEW, OpenVibe también tiene la ventaja de que es compatible con varios equipos de EEG.

## ○ **Filtrado**

Por lo general, cuando se obtiene cualquier tipo de señal, la señal se encuentra contaminada por ruido electromagnético. Es por esta razón que el filtrado juega un papel muy importante al momento de procesar y extraer la información de la señal obtenida. Existen dos tipos básicos de filtros lineales que son los filtros pasa bajas (solo dejan pasar las bajas frecuencias) y filtros pasa altas (solo dejan pasar las altas frecuencias). Sin embargo, si se usan ambos simultáneamente es posible generar filtros pasa bandas (solo dejan pasar frecuencias dentro de un rango específico) y rechaza bandas (eliminan frecuencias dentro de un rango específico).

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

La figura 10 muestra cómo se varia cada uno de estos filtros graficados en el dominio de la frecuencia.



**Figura 10:** Tipos de filtros (Nilsson & Reidel, 2005)

- (a) Filtro pasa bajas
- (b) Filtro pasa altas
- (c) Filtro pasa bandas
- (d) Filtro rechaza bandas

De esta manera, sería posible aislar las señales dentro del rango de frecuencia de 8-30 Hz (rango en el cual se encuentran las señales sensoriomotoras) utilizando un filtro pasa bandas.

Además de esto, existen también los filtros no lineales. Un filtro no lineal comúnmente utilizado es el filtro Laplaciano. El filtro Laplaciano sirve para encontrar cambios drásticos en la intensidad de un conjunto de datos aplicando derivadas. Aunque normalmente es aplicado para el procesamiento de imágenes, también puede ser útil para filtrar espacialmente señales de EEG (Fisher, Perkins, Walker & Wolfart, 2000).

El Laplaciano  $L(x, y)$  de una matriz con valores de intensidad  $I(x, y)$  es dado por:

$$L(x, y) = \frac{\partial^2 I}{\partial x^2} + \frac{\partial^2 I}{\partial y^2}$$

Esto puede ser calculado usando un filtro de convolución.

Esto ya dicho, no basta con solo aplicar un filtro pasa bandas y filtros Laplacianos para poder llevar acabo más adelante la clasificación de la señal. Por esta razón es necesario aplicar otro tipo de filtro llamado Common Spatial Pattern (Patrón espacial común o CSP por sus siglas en ingles). De

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

igual manera que el filtro Laplaciano, el filtro CSP filtra la señal espacialmente y no frecuencialmente.

El propósito de utilizar un filtro CSP consiste en maximizar la varianza de una clase de movimientos mientras se minimiza para otra con el fin de distinguir entre estas dos clases con mayor facilidad (ej: Flexionar el brazo y no hacer nada). Es posible lograr esto llevando a cabo la siguiente demostración matemática (Costa, Møller, Iversen & Puthusserypady, 2018):

Siendo  $\mathbf{X}_j \in \mathbb{R}^{Cn \times N}$  el  $j$ -ésimo ensayo,  $N$  el número de muestras por ensayo y  $Cn$  el número de canales EEG, sería posible definir la señal filtrada  $\mathbf{Z}_{j,CSP} \in \mathbb{R}^{Cn \times N}$  como:

$$\mathbf{Z}_{j,CSP} = \mathbf{W} \mathbf{X}_j \quad (1)$$

Donde  $\mathbf{W} \in \mathbb{R}^{Cn \times Cn}$  es la matriz que parametriza la descomposición de la señal. Cada columna de  $\mathbf{W}$  equivale a un filtro espacial y cada columna de  $\mathbf{W}^{-1}$  como un patrón espacial.

Una de las maneras para obtener  $\mathbf{W}$  consiste en realizar la diagonalización común de las matrices de covarianza para ambas clases. Lo que significa que podemos definir la matriz normalizada de covarianza para la clase  $k$  como:

$$\mathbf{C}_k = \frac{1}{T_n} \sum_{j=1}^{T_n} \frac{\mathbf{X}_{j(k)} \mathbf{X}_{j(k)}^T}{\text{trace}(\mathbf{X}_{j(k)} \mathbf{X}_{j(k)}^T)} \quad (2)$$

En donde  $T_n$  es el número de ensayos,  $\mathbf{X}_{j(k)}$  es el  $j$ -ésimo perteneciente a la clase  $k \in [1, K]$  en donde  $K = 2$  para un problema de clasificación binaria.

El análisis CSP se hace entonces con la diagonalización común de las dos matrices de covarianza:

$$\begin{aligned} \mathbf{W} \mathbf{C}_1 \mathbf{W}^T &= \mathbf{\Lambda}_1 \\ \mathbf{W} \mathbf{C}_2 \mathbf{W}^T &= \mathbf{\Lambda}_2 \end{aligned} \quad (3)$$

Donde  $\mathbf{\Lambda}_k$  es la matriz diagonal de eigenvalores y  $\mathbf{W}$  son los eigenvectores. El escalamiento de  $\mathbf{W}$  es determinado de manera que  $\mathbf{\Lambda}_1 + \mathbf{\Lambda}_2 = \mathbf{I}$ . Esto se logra resolviendo la Descomposición Generalizada de Eigenvalores (GED por sus siglas en inglés):

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

$$\mathbf{C}_1 \mathbf{w}_i = \lambda_i \mathbf{C}_2 \mathbf{w}_i \quad (4)$$

donde  $\lambda_i = \mathbf{w}_i^T \mathbf{C}_k \mathbf{w}_i$  es el  $i$ -ésimo eigenvalor en  $\mathbf{\Lambda}_k$  y  $\mathbf{w}_i$  son los vectores columna de  $\mathbf{W}$ .

La solución al problema de GED:


- Calcular la covarianza espacial compuesta  $\mathbf{C}_{cp} = \mathbf{C}_1 + \mathbf{C}_2$ ;
- Factoriza  $\mathbf{C}_{cp}$ :  $\mathbf{C}_{cp} = \mathbf{U}_c \mathbf{\Lambda}_c \mathbf{U}_c^T$ , donde  $\mathbf{U}_c$  es la matriz de eigenvectores;
- Igualando la varianza en el espacio generado por  $\mathbf{U}_c$  aplicando la transformada de Whitening:  $\mathbf{P} = \sqrt{\frac{1}{\mathbf{\Lambda}_c}} \mathbf{U}_c^T$ ;
- Transformando  $\mathbf{C}_1$  y  $\mathbf{C}_2$ :  $\mathbf{S}_k = \mathbf{P} \mathbf{C}_k \mathbf{P}^T$ ;

Nota:  $\mathbf{S}_1$  y  $\mathbf{S}_2$  comparten eigenvectores comunes  $\mathbf{B}$  y, como fue visto antes,  $\mathbf{\Lambda}_1 + \mathbf{\Lambda}_2 = \mathbf{I}$ . De esta manera, los eigenvectores con los eigenvalores más grandes para la clase 1 tienen los eigenvectores más pequeños para la clase 2, y viceversa. Por esta razón, tomando los  $m$  primeros y últimos eigenvectores de  $\mathbf{B}$  y usandolos para proyectar los datos de EEG se logra obtener las características más discriminativas para poder distinguir entre la clase 1 y la clase 2.

- Se obtiene la matriz de proyección  $\mathbf{W} = (\mathbf{B}^T \mathbf{P})^T$ .

## ○ LDA

Una vez filtradas las señales y habiendo extraído ya las características de cada clase es posible realizar el aprendizaje de maquina necesario para clasificarlas. Para esto existe una técnica conocida como Análisis Discriminativo Lineal (LDA por sus siglas en ingles). Consiste en maximizar la rata de varianza entre clases con respecto a la varianza dentro de la misma clase para de esta manera reducir la variación de los datos dentro de la misma clase y simultáneamente aumentar la separación entre las clases (Li & Wang, 2014).



**Figura 11:** Ejemplo LDA (Li & Wang, 2014)

Partiendo de la ecuación  $\mathbf{y} = \boldsymbol{\theta}^T \mathbf{X}$ , se busca proyectar los datos  $\mathbf{X}$  sobre una línea  $\mathbf{y}$ . LDA busca encontrar el ángulo  $\boldsymbol{\theta}$  que maximice el valor del escalar  $\mathbf{y}$  y de esta manera distinguir con mayor certeza entre las dos clases

Para esto es necesario encontrar función  $J(\boldsymbol{\theta})$  que defina este ángulo. Asumamos que tenemos un set de D-dimensiones de muestras  $\mathbf{X} = \{x^{(1)}, x^{(2)}, \dots, x^{(m)}\}$ ,  $N_1$  de los cuales pertenecen a la clase  $C_1$ , y  $N_2$  de los cuales pertenecen a la clase  $C_2$ . Además, asumimos que el vector promedio de las dos clases en el espacio-X es:

$$u_k = \frac{1}{N_k} \sum_{i \in C_k} x^{(i)} \text{ donde } k = 1, 2. \quad (1)$$

Y en el espacio-Y:

$$\hat{u}_k = \frac{1}{N_k} \sum_{i \in C_k} y^{(i)} = \frac{1}{N_k} \sum_{i \in C_k} \boldsymbol{\theta}^T x^{(i)} = \boldsymbol{\theta}^T u_k \text{ donde } k = 1, 2. \quad (2)$$

Una manera de definir la medida de separación entre las dos clases es escoger la distancia entre los promedios proyectados, los cuales están en el espacio-Y, entonces la varianza entre clases se puede definir como:

$$\hat{u}_2 - \hat{u}_1 = \boldsymbol{\theta}^T (u_2 - u_1) \quad (3)$$

Podemos también definir la varianza dentro de la clase  $C_k$  como:

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

$$\hat{S}_k^2 = \sum_{i \in \mathcal{C}_k} (y^{(i)} - \hat{u}_k)^2 \text{ donde } k = 1, 2. \quad (4)$$

Usando la varianza entre clases y la varianza dentro de la misma clase podemos definir la función  $J(\theta)$  como:

$$J(\theta) = \frac{(\hat{u}_2 - \hat{u}_1)^2}{\hat{S}_1^2 + \hat{S}_2^2} \quad (5)$$

Sin embargo, para poder encontrar el ángulo óptimo es necesario definir  $J(\theta)$  en términos de  $\theta$ . Para esto es necesario reemplazar la varianza por la dispersión.

Lo que nos lleva a definir las siguientes igualdades:

- La dispersión de características en el espacio-X:  $S_k = \sum_{i \in \mathcal{C}_k} (x^{(i)} - u_k)(x^{(i)} - u_k)^T$
- La matriz de dispersión dentro de la misma clase:  $S_W = S_1 + S_2$
- La matriz de dispersión entre las dos clases:  $S_B = (u_2 - u_1)(u_2 - u_1)^T$

Tras una serie de demostraciones matemáticas se llega finalmente a que:

$$J(\theta) = \frac{\theta^T S_B \theta}{\theta^T S_W \theta} \quad (6)$$

Derivando la ecuación anterior e igualándola a cero retorna el ángulo óptimo para la proyección de los datos sobre escalar  $y$ .

## 2. METODOLOGÍA


### 2.1 DESARROLLAR UN ALGORITMO QUE RECONOZCA PATRONES DE LA SEÑAL EEG Y ACCIONE EL DISPOSITIVO DE ESTIMULACIÓN MUSCULAR.

#### 2.1.1 Descargar sets de señales EEG (disponibles en bases de datos de internet)

El set de datos proviene de “BCI Competition 2008 – Graz data set A” (Brunner et al, 2008). El propósito de esta competencia fue dar acceso abierto a información neurológica para promover el desarrollo de nuevas soluciones en el campo de la neuroingeniería. Imponiendo ciertos reglamentos para el procesamiento de la información se ha asegurado que los resultados obtenidos por diferentes personas puedan ser comprados. Por este motivo, varios estudios han decidido basar sus hallazgos sobre diferentes técnicas de filtrado y procesamiento en el “BCI Competition 2008 – Graz data set A”. Tomando esto en consideración, se decidió hacer lo mismo y así lograr tener un punto de referencia bien establecido con respecto a publicaciones anteriores.

Los datos consistían en señales EEG de 9 personas diferentes. A cada persona se le pedía el favor de realizar 4 diferentes tipos de imágenes motoras: Clase 1, imaginar movimientos con la mano izquierda; Clase 2, movimiento con la mano derecha; clase 3, con los pies; Clase 4, con la lengua. La indicación de que imagen motora debían realizar era dada aleatoriamente por una imagen que se mostraba en una pantalla. En total, el experimento estuvo compuesto de 2 sesiones, cada una en días separados. Una sesión está compuesta de 6 grabaciones con 48 ensayos (12 para cada imagen motora) por grabación, sumando a un total de 288 ensayos.


El ensayo empezaba con una advertencia acústica seguida de una cruz en el centro de la pantalla. Después de 2 segundos aparecía una flecha en la pantalla indicando cuál de las 4 intenciones motoras tenía que ser imaginada (izquierda, derecha, abajo y arriba corresponden a la dirección que apunta la flecha para las clases 1, 2, 3 y 4 en ese respectivo orden). La figura 12 muestra el esquema temporal que se siguió para grabar los ensayos.



**Figura 12:** Esquema temporal del paradigma (Brunner et al, 2008).

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

Los datos fueron obtenidos utilizando 22 electrodos como se muestra en la figura 13 con una frecuencia de muestro de 250 Hz. Posteriormente se utilizó un filtro pasa-bandas entre 0.5 Hz y 100 Hz, junto con un filtro notch en 50 Hz para eliminar el ruido electromagnético de las fuentes de alimentación.



**Figura 13:** Posicionamiento de los electrodos en BCI Competition 2008 (Brunner et al, 2008).

La tabla 3 muestra los valores Kappa que obtuvieron los ganadores de la competencia. El ganador utilizó FBCSP (Banco de filtros CSP). El FBCSP funciona bajo el mismo paradigma que el filtro CSP solo que es aplicado en varios intervalos cortos de frecuencia a diferencia de un gran intervalo como el CSP.

Contribuyente	Kappa	1	2	3	4	5	6	7	8	9
Kai Keng Ang	0.57	0.68	0.42	0.75	0.48	0.40	0.27	0.77	0.75	0.61
Liu Guangquan	0.52	0.69	0.34	0.71	0.44	0.16	0.21	0.66	0.73	0.69
Wei Song	0.31	0.38	0.18	0.48	0.33	0.07	0.14	0.29	0.49	0.44
Damien Coyle	0.30	0.46	0.25	0.65	0.31	0.12	0.07	0.00	0.46	0.42
Jin Wu	0.29	0.41	0.17	0.39	0.25	0.06	0.16	0.34	0.45	0.37

**Tabla 3:** Resultados de la BCI Competition 2008 (BCI Competition IV: Results, 2019)

### 2.1.2 Extraer los datos de importancia de cada set de señales en arreglos vectoriales

Inicialmente se decidió extraer los intervalos de tiempo que contenían la imagen motora realizada, usando MATLAB R2018b. Esto se debe a que en la página web de la competencia se recomendaba usar una extensión de MATLAB llamada BIOSIG toolbox para leer los datos, los cuales se encontraban en formato GDF. Tras haber investigado más sobre diferentes programas para la extracción de los datos se encontró dos librerías para Python hechas con el propósito de atacar este tipo de problemas interfaz cerebro computador. La librería de MNE creada por Gramfort y demás (Gramfort et al, 2013) y la librería MOABB creada por Barachant y Jayaram (Barachant & Jayaram, 2018) poseen la ventaja de ser open-source, esto significa que la gente utiliza el código


La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.



puede editarlo y contribuir para que cada vez este se vaya volviendo más robusto y completo. Además, ambos códigos poseen la ventaja de trabajar con Python, que, a diferencia de MATLAB, los scripts de Python son compatibles con varios ordenadores de placa reducida como la Raspberry Pi. En un futuro esto permitiría implementar el algoritmo para un dispositivo portátil. Igualmente, se realizó este mismo proceso con la ayuda de la interfaz gráfica de programación OpenVibe, creada por Renan y demás (Renan et al, 2010). Esto se debe a su compatibilidad con archivos GDF y la posibilidad de usarlo directamente con el equipo EEG g.USBamp, facilitando en un futuro al usuario la extracción y procesamiento de los datos en tiempo real.

### **2.1.3 Desarrollar un algoritmo que, mediante los vectores extraídos, sea capaz de reconocer la imagen motora que produjo cada sujeto**

El algoritmo de MATLAB en este paso de la metodología se logró mediante el uso del toolbox creado por Lotte y Guan, el cual se podía descargar al igual de BIOSIG, para implementar funciones de filtrado como CSP y la extracción de los vectores característicos de este filtro (Lotte & Guan, 2011). Posteriormente se entrenaron diferentes clasificadores con el propósito de identificar cual brindaba un porcentaje más alto clasificaciones correctas. Siguiendo los mismos pasos hecho en MATLAB y tomando como base los algoritmos disponibles en MNE y MOABB fue posible implementar filtros CSP para obtener los arreglos vectoriales de cada clase, compuestos de sus características respectivas. Por último, se repitió el mismo proceso dicho previamente usando la interfaz OpenVibe. La figura 14 muestra un diagrama de flujo con el procedimiento general de extracción y procesamiento de datos para todos los programas que han sido mencionados hasta el momento (MATLAB, Python y OpenVibe).



**Figura 14:** Diagrama de flujo para extracción y procesamiento de datos

Tanto en MATLAB, Python y OpenVibe solo se hizo la clasificación de dos de las clases aun que el set de datos contenía 4 clases. El filtro CSP funciona específicamente para dos clases, sin embargo, puede ser adaptado para solucionar problemas multiclases. El problema del presente proyecto solo deberá clasificar entre 2 clases, razón por la cual no se consideró necesario profundizar en el desarrollo de un algoritmo de preprocesado y clasificación de un problema multiclase. A continuación, se mostrará una tabla con los resultados de las clasificaciones obtenidas por MATLAB, Python y OpenVibe.

Sujeto	MATLAB	Python	OpenVibe
1	84.6%	83.4%	80.73%
2	86.3%	64.1%	70.81%
3	90.7%	95.1%	92.42%
4	80.5%	55.1%	76.99%
5	87.0%	65.1%	68.31%
6	79.5%	70.0%	78.35%
7	89.3%	72.4%	78.64%
8	94.3%	91.7%	91.27%
9	86.9%	89.6%	75.11%

**Tabla 4:** Resultados de clasificación para BCI Competition IV 2a con MATLAB, Python, y OpenVibe.

La tabla 4 muestra los resultados de clasificación obtenidos utilizando MATLAB, Python, y OpenVibe para procesar el set de datos de la competencia BCI IV 2a utilizando un filtro butterworth pasa bandas entre 8-30 Hz (frecuencia en la que sucede el primer los ritmos mu y beta), junto con un filtro CSP y un clasificador LDA. Es evidente que los resultados fueron muy similares en ciertos sujetos y muy diferentes en otros.

## **2.2 UN SISTEMA DE ADQUISICIÓN Y PROCESAMIENTO DE LAS SEÑALES EEG HUMANAS EN TIEMPO REAL.**

### **2.2.1 Diseño del experimento que será utilizado para obtener señales EEG**

Para la extracción de datos de los sujetos de prueba que participaran en el trabajo se desarrolló un procedimiento similar al de la competencia BCI IV 2a. El experimento consiste en mostrar en la pantalla del computador que se encuentra conectado al equipo g.USBamp una de dos instrucciones diferentes de manera aleatoria. Las instrucciones aparecen de manera aleatoria para evitar que el sujeto se prepare mentalmente para la tarea a realizar y de esta manera asegurar que los resultados sean más acordes al uso que recibiría el dispositivo durante el día a día por los pacientes con accidente cerebrovascular cerebral.

Para las sesiones de entrenamiento offline los sujetos de investigación deberán realizar 6 sesiones de grabación de datos. Durante la primera sesión deberán de ejecutar flexión del brazo dominante cuando aparezca en la pantalla del computador una flecha apuntando hacia arriba y no hacer nada cuando aparezca una flecha apuntando hacia abajo. Este procedimiento se deberá repetir 10 veces para cada una de las instrucciones que serán separadas por intervalos cortos de descanso,

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

sumando a un total de 20 ensayos por sesión. La segunda sesión el sujeto deberá repetir un procedimiento similar al anterior, sin embargo, en este caso deberá imaginar que lleva acabo lo que se le indica en la pantalla del computador (flexión del brazo cuando aparece una flecha apuntando arriba y nada cuando sale una flecha apuntando hacia abajo) 10 veces para cada clase. Nuevamente, las instrucciones serán mostradas de manera aleatoria, separadas por intervalos cortos de descanso, generando un total de 20 ensayos por sesión. Se repetirá el procedimiento de las dos sesiones mencionadas anteriormente otras dos veces. Se decidió seguir el mismo paradigma utilizado en la BCI Competiton IV 2a como se muestra en la figura 12 excluyendo el pito inicial al principio de cada ensayo.

Una vez se obtengan unos porcentajes de clasificación los suficiente altos será posible proceder a las sesiones online. Durante las sesiones online se le pedirá al sujeto encender y apagar el sistema de electroestimulación.

### **2.2.2 Adquirir señales EEG en tiempo real utilizando g.GAMMAcap**

El equipo g.GAMMA está compuesto de 4 partes que son los electrodos, el amplificador, la caja a la que se conectan los electrodos y el casco de EEG que se coloca sobre la cabeza del paciente. La figura 15 muestra los electrodos secos g.SAHARA utilizados. La figura 16 muestra el g.SAHARAbbox que conecta los electrodos al amplificador. La figura 17 muestra el equipo g.USBamp para la amplificación de las señales. Por último, la figura 18 muestra el g.GAMMAcap que sostiene los electrodos sobre la cabeza del paciente utilizando el sistema de referencia 10-20.



**Figura 15:** Electrodos secos g.SAHARA (g.tec medical engineering, 2019)



**Figura 16:** g.GAMMAbox (g.tec medical engineering, 2019)

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.



**Figura 17:** Amplificador g.USBamp (g.tec medical engineering, 2019)



**Figura 18:** g.GAMMAcap (g.tec medical engineering, 2019)

### **2.2.3 Probar el algoritmo diseñado para las señales de las bases de datos en las señales obtenidas por la g.GAMMAcap (hacer ajustes si se requieren)**

Para el experimento, se hicieron mediciones para 4 diferentes personas. A cada persona se le informo que debido a que se estaría trabajando con corrientes eléctricas, existía la posibilidad de sufrir una breve irritación en la piel causada por el circuito de electroestimulación. Una vez informados, a cada sujeto de investigación se le pidió firmar un acuerdo. Firmado el acuerdo se prosiguió a leer las siguientes instrucciones:

- I. Usted será conectado al el equipo g.USBamp para obtener la señal de electroencefalografía (señales cerebrales).
  - a. El equipo consta de un gorro elástico al cual se encuentran conectadas 16 terminales.
  - b. Todas las terminales van conectadas a un equipo que sirve como el intermediario entre la persona y el computador
- II. Posteriormente deberá sentarse al frente de la pantalla de un computador.
  - a. Antes de comenzar el experimento se realizarán unas pruebas con el computador para asegurarse que las señales obtenidas si sean adecuadas.
- III. El computador exhibirá un set de instrucciones que usted deberá de llevar acabo (cada set de instrucciones dura aproximadamente 5 minutos).
- IV. El primer set de instrucciones consistirá en realizar contracción del brazo.
- V. Una flecha apuntando hacia arriba indica flexionar el brazo y una flecha apuntando hacia abajo indica no hacer nada.
- VI. El segundo set de instrucciones el participante tendrá que imaginar este movimiento, mas no ejecutarlos físicamente.
- VII. Nuevamente las flechas apuntando hacia arriba o hacia abajo indicaran la tarea mental que se debe realizar. Flecha arriba indica imaginar la flexión del brazo, flecha abajo no hacer nada.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

- VIII. Se repetirán los pasos IV y V otras dos veces (Lo que significa que el experimento durara un total de 30 minutos)
- IX. Utilizando los datos obtenidos es posible entrenar unos filtros digitales específicos a sus señales cerebrales para que sean capaces de reconocer la intención motora que usted desea llevar a cabo.
- X. Finalmente, una vez entrenado el programa para reconocer su intención motora, se realizará una sesión en tiempo real en la cual usted controlará un dispositivo de electroestimulación ubicado en su antebrazo.

Vale aclarar que las sesiones de entrenamiento offline y la sesión online se hicieron en días separados.

A lo último se decidió optar por el algoritmo diseñado en el programa OpenVibe por la compatibilidad que ofrecía el programa con el equipo de EEG g.USBamp, tanto en la adquisición de datos, como en el diseño de la interfaz visual necesaria a la hora de dar las instrucciones a los sujetos de investigación.

Las ilustraciones de la 19-23 muestran a uno de los participantes durante la medición de señales de la primera sesión.



**Figura 19:** Extracción de señales

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.




**Figura 20:** Extracción de señales



**Figura 21:** Extracción de señales

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.





**Figura 22:** Extracción de señales



**Figura 23:** Extracción de señales

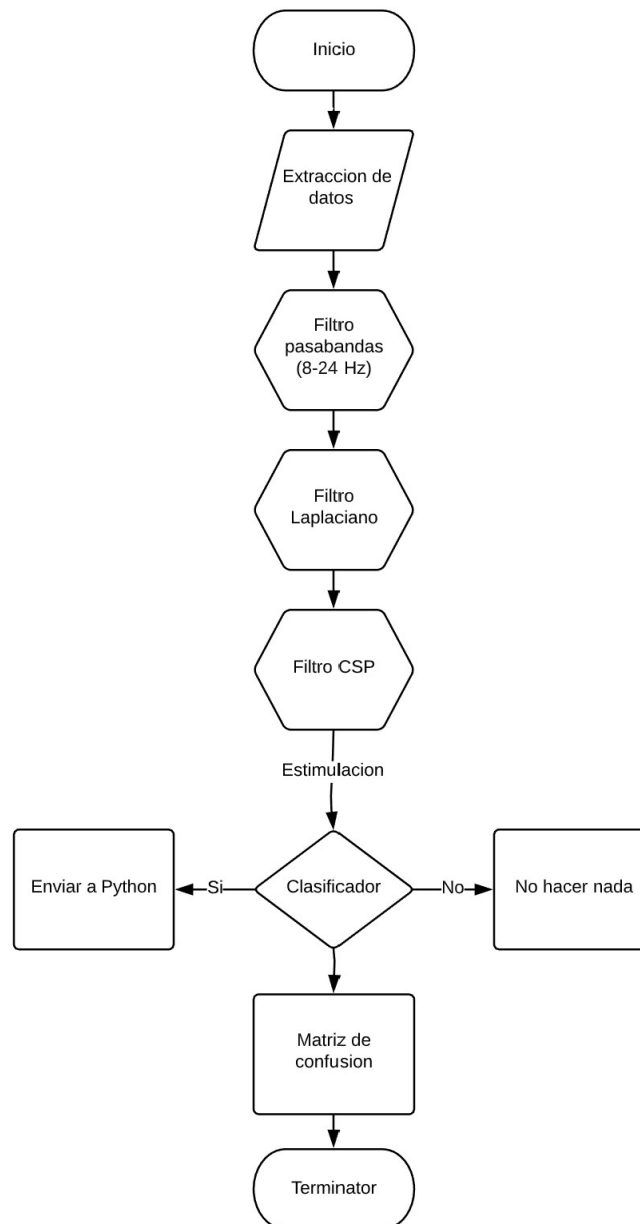
#### **2.2.4 Encender y apagar un LED usando el algoritmo final**

Una vez obtenidas las señales del paso anterior y entrenados los filtros y clasificadores de cada sujeto de investigación, fue posible pasar al último paso que era expresar estas estimulaciones generadas por el clasificador como unos y ceros analógicos. Para esto fue necesario comunicarse desde OpenVibe con Python y de Python mandar un alto o un bajo de voltaje a Arduino. De esta manera será entonces posible controlar el circuito externo de electroestimulación.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.




Por cuestiones de simplicidad se optó por comenzar controlando un LED. Si se logra esto entonces solo se debe reemplazar el LED por el circuito de electroestimulación. La figura 24 muestra un diagrama de flujo que ejemplifica el código con el cual se extrajo y se filtró la señal en tiempo real a través de OpenVibe.



**Figura 24:** Diagrama de flujo para extracción y procesamiento de datos (Tiempo real)

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

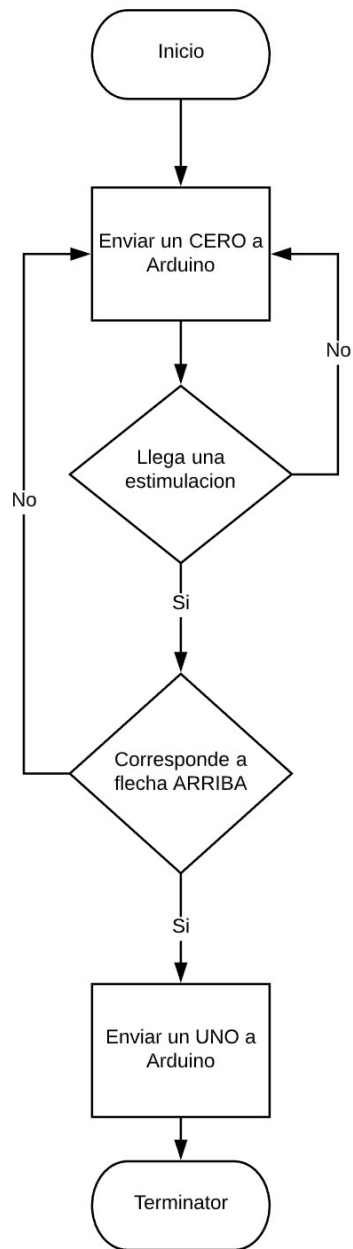
El diagrama es similar al que se muestra en la figura 14. Las únicas dos diferencias significativas son: Este programa cuenta con un filtro Laplaciano y además es capaz de mandar los estímulos que recibe el clasificador a la interfaz de Python. El filtro Laplaciano no fue implementado originalmente cuando se trabajó con las señales de las bases de datos, ya que no había un archivo que contuviera la posición en la que fueron ubicados los electrodos (con referencia al sistema 10-20 usando medidas cartesianas) durante el experimento. Por el contrario, para este experimento se sabe exactamente dónde estaba ubicado cada uno de los electrodos con respecto al sistema 10-20 como se muestra en la figura 25.



**Figura 25:** Posición electrodos

El siguiente diagrama de flujo (figura 26) muestra el código que se implementó en Python para recibir las estimaciones generadas de OpenVibe y a partir de ahí controlar los altos y los bajos generados por el Arduino.

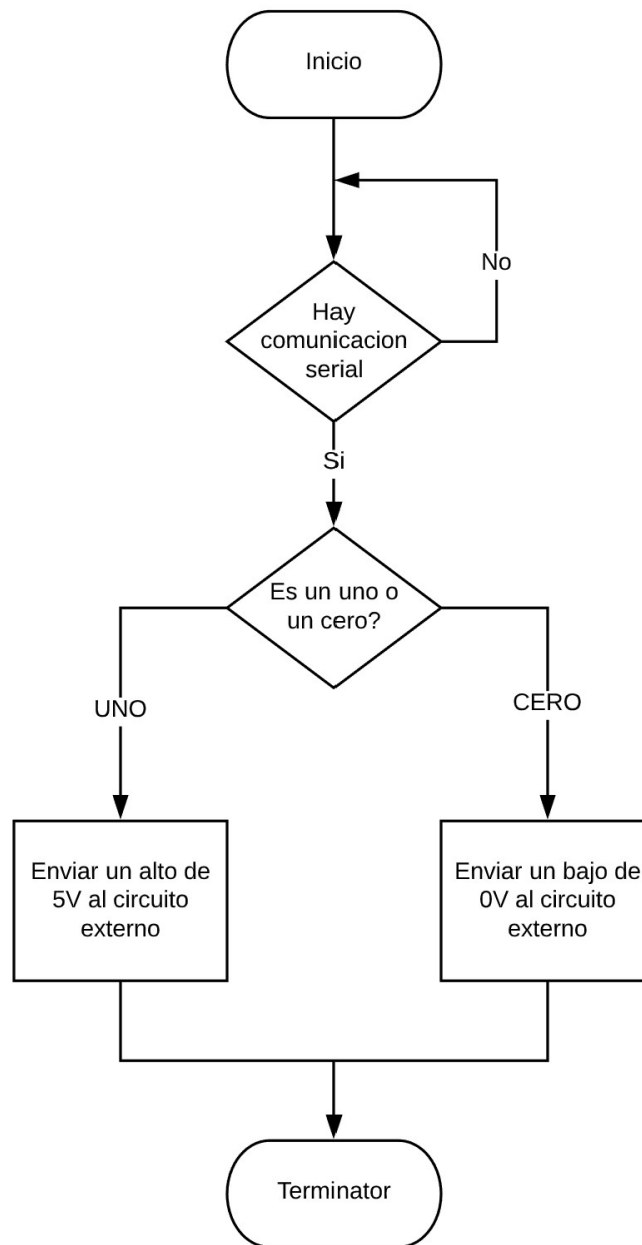
La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.



**Figura 26:** Diagrama de flujo para enviar estímulos de Python a Arduino

Por último, se muestra el diagrama de flujo (figura 27) que representa el programa con el cual se leían los unos y los ceros enviados por Python, en Arduino.


La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.



**Figura 27:** Diagrama de flujo para recibir estímulos de Python en Arduino

La razón por la cual no se obtuvieron las señales usando Python desde un principio es porque Python no es compatible con el equipo g.USBamp. Esto significa que no se pueden extraer y procesar en tiempo real desde la interfaz de Python, deben ser primero extraídas y posteriormente procesadas.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.




**Figura 28:** Encendido del LED.

Como se evidencia en la figura 28, se logró controlar el encendido y apagado del LED. Lo que significa que sería efectivamente posible controlar el circuito de electroestimulación. La barra azul que se puede ver en la pantalla del computador sirve como retroalimentación visual para el usuario para indicarle que tan bien está modulando la señal sensoriomotora. Entre más se mueva la barra hacia la derecha es porque mejor se está modulando la imagen motora de flexionar el brazo, y entre más se mueva hacia la izquierda es porque mejor se está modulando la imagen motora de no hacer nada.

## **2.3 IMPLEMENTAR UN SISTEMA PARA LA ESTIMULACIÓN MUSCULAR DEL ANTEBRAZO PARA INDUCIR UN MOVIMIENTO.**

### **2.3.1 Bosquejo del circuito de electroestimulación**

Partiendo del diseño hecho por la egresada María Clara Mejía para su tesis, se hizo un circuito con base a las siguientes ilustraciones (29-35):



**Figura 29:** Diagrama de bloques de electroestimulación (Mejía, 2017)


La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

- Control de frecuencia: Usando un timer 555 en modo aestado, es posible controlar la frecuencia del pulso de ondas utilizando un potenciómetro. (Figura 30)



**Figura 30:** Etapa de control de frecuencia (Mejia, 2017)

- Generación de tren de pulsos: Nuevamente, se utiliza un potenciómetro para regular el número de pulsos durante el tiempo en alto. (Figura 31)



**Figura 31:** Generación de tren de pulsos (Mejia, 2017)


La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

- Control de tiempo en alto: Es posible, usando el tren de pulsos, activar un timer 555 en configuración monoestable con el flanco de bajada de uno de los pulsos del tren de pulsos. Utilizando un potenciómetro se logra controlar el momento que la señal del timer coincide con el flanco de bajada del tren de pulsos y por ende el tiempo en alto. (Figura 32)



**Figura 32:** Control de tiempo en alto (Mejia, 2017)

- Conmutación de la señal: Por medio de un transistor se controla la conmutación de la señal. (Figura 33)



**Figura 33:** conmutación de la señal (Mejia, 2017)

- Aumento de tensión de la señal: Debido a que el voltaje de la señal generada no es suficiente para electroestimular el músculo es necesario el uso de un transformador que entregue 110V a la salida. (Figura 34)



**Figura 34:** Aumento de tensión de la señal (Mejia, 2017)

- Control de la intensidad: La intensidad necesaria para electroestimular el músculo puede variar entre pacientes, es por esta razón que es necesario implementar un potenciómetro el cual permita regular la intensidad de la señal de salida. (Figura 35)




**Figura 35:** Control de intensidad (Mejia, 2017)

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.




### 2.3.2 Montar el circuito en una protoboard y hacer los ajustes necesarios hasta tener el funcionamiento deseado



**Figura 36:** Prototipo final (protoboard)

El prototipo final de la figura 36 carece del tercer LM555. Esto se debe a que ese tercer LM555 cumplía la función de un temporizador. En otras palabras, controlaba la duración del estímulo eléctrico. En este trabajo los sujetos de investigación controlarían la duración del estímulo mediante la señal de EEG por lo que no se consideró necesario.

Además de esto se verificó, usando un osciloscopio y alimentando el circuito con una fuente de voltaje a 5V, que la corriente de la señal moduladora no superara los 120mA y que su frecuencia se mantuviera entre 10Hz (una menor frecuencia y podría generar contracción vibratoria) y 100Hz (una mayor frecuencia podría no permitir la repolarización del músculo).




**Figura 37:** Tren de pulsos (Mejia, 2017)

Mirando la figura 37 se puede obtener una idea de la forma de la señal moduladora que controlara el electroestimulador.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

### 2.3.3 Soldar el circuito de la protoboard en una tarjeta PCB para ahorrar espacio y un mejor desempeño.




**Figura 38:** Electroestimador en tarjeta PCB

(Figura 38) Prototipo inicial del electroestimador soldado en tarjeta PCB. Solo falta por soldar el transformador.

### 2.3.4 Ensamblar todos los componentes electrónicos que en conjunto serán el dispositivo BCI/FES y probar funcionamiento (hacer ajustes si se requieren)

Para probar el circuito de electroestimulación con el programa antes de hacer las pruebas de tiempo real en los sujetos de investigación, se utilizó un set de señales ya grabadas de uno de los participantes. Tras hacer esto, se evidencio que a pesar de que el pin de salida (en este caso el pin 8 conectado a tierra como se puede ver en la figura 39) del Arduino tenía el mismo voltaje de 5V con el cual se probó en la fuente de voltaje, pero la corriente era muy baja como para poder genera un estímulo eléctrico.




**Figura 39:** Arduino Uno (Arduino, s.f)

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

Buscando otras alternativas, se descubrió que si se utilizaba el pin de 5V (figura 40) que posee el Arduino para alimentar el circuito de electroestimulación, era entonces posible obtener la corriente necesaria para activar el circuito de electroestimulación.

**Figura 40:** Arduino Uno (Arduino, s.f)


De esta manera fue posible solucionar el problema utilizando un transistor 2N3904 que a la base tuviera conectado el pin 8 de salida, al colector el pin de 5V y al emisor el pin de tierra. Mirar figura 41.



**Figura 41:** Conexión pines Arduino

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

La figura 42 muestra como quedo el circuito final de electroestimulación que será usado para las pruebas en tiempo real.



**Figura 42:** Electroestimulador versión final

La parte resaltada corresponde al transistor 2N3904 que fue adicionado.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

### 3. PRESENTACIÓN Y DISCUSIÓN DE RESULTADOS

Esta sección constara de dos partes: Los valores obtenidos para las sesiones offline y el posterior desempeño de los sujetos de investigación durante las sesiones online usando el electroestimulador.

#### 3.1 SESIONES OFFLINE

Las sesiones offline fueron llevadas a cabo en el laboratorio de electrónica de la Universidad EIA, sede Zúñiga. A continuación, se mostrarán los resultados obtenidos para cada sujeto de investigación. A pesar de que los porcentajes de distinción entre las dos clases fueron buenos para algunas de las mediciones de movimiento real y/o de movimiento imaginario, hubo ciertos sujetos que mostraron una gran variabilidad en por lo menos una de las sesiones con respecto al resto al resto. Se cree que las tres principales razones que pudieron haber ocasionado estas discrepancias son: Distracciones durante la toma de datos, fatiga mental, y el ruido generado por los otros dispositivos electrónicos del laboratorio.

Es posible evidenciar que los promedios para el movimiento real fueron mucho mayores que para los movimientos imaginados. Esto se debe a que a pesar de que las dos señales son muy similares, realizar el movimiento puede generar una señal de mayor amplitud que solo imaginarlo. Si la señal es de mayor amplitud, entonces resulta más fácil extraer sus características y filtrarla. Las matrices de confusión que se muestran a continuación comparan los resultados obtenidos para cada clase con respecto a la clase objetivo.

##### 3.1.1 Sujeto 1

###### ○ Movimiento Real

Referenciando la tabla 5, el sujeto 1 tuvo un porcentaje de calificación promedio de 78%.

	Clase Resultado (Nada)	Clase Resultado (Flexión)
Clase Objetivo (Nada)	0.94	0.06
Clase Objetivo (Flexión)	0.38	0.62

**Tabla 5:** Movimiento Real, Sujeto 1, Primera Sesión

Referenciando la tabla 6, el sujeto 1 tuvo un porcentaje de calificación promedio de 75.2%.

	Clase Resultado (Nada)	Clase Resultado (Flexión)
--	------------------------	---------------------------

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

Clase Objetivo (Nada)	0.79	0.21
Clase Objetivo (Flexión)	0.28	0.72

**Tabla 6:** Movimiento Real, Sujeto 1, Segunda Sesión

Referenciando la tabla 7, el sujeto 1 tuvo un porcentaje de calificación promedio de 64%.

	Clase Resultado (Nada)	Clase Resultado (Flexión)
Clase Objetivo (Nada)	0.64	0.36
Clase Objetivo (Flexión)	0.36	0.64

**Tabla 7:** Movimiento Real, Sujeto 1, Tercera Sesión

○ **Movimiento Imaginado**

Referenciando la tabla 8, el sujeto 1 tuvo un porcentaje de calificación promedio de 53.4%.

	Clase Resultado (Nada)	Clase Resultado (Flexión)
Clase Objetivo (Nada)	0.21	0.79
Clase Objetivo (Flexión)	0.14	0.86

**Tabla 8:** Movimiento Imaginado, Sujeto 1, Primera Sesión

Referenciando la tabla 9, el sujeto 1 tuvo un porcentaje de calificación promedio de 62.4%.

	Clase Resultado (Nada)	Clase Resultado (Flexión)
Clase Objetivo (Nada)	0.71	0.29
Clase Objetivo (Flexión)	0.46	0.54

**Tabla 9:** Movimiento Imaginado, Sujeto 1, Segunda Sesión

Referenciando la tabla 10, el sujeto 1 tuvo un porcentaje de calificación promedio de 69%.

	Clase Resultado (Nada)	Clase Resultado (Flexión)
Clase Objetivo (Nada)	0.60	0.40

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

Clase Objetivo (Flexión)	0.22	0.78
--------------------------	------	------

**Tabla 10:** Movimiento Imaginado, Sujeto 1, Tercera Sesión

### 3.1.2 Sujeto 2

#### ○ **Movimiento Real**

Referenciando la tabla 11, el sujeto 2 tuvo un porcentaje de calificación promedio de 70.8%.

	Clase Resultado (Nada)	Clase Resultado (Flexión)
Clase Objetivo (Nada)	0.84	0.16
Clase Objetivo (Flexión)	0.42	0.58

**Tabla 11:** Movimiento Real, Sujeto 2, Primera Sesión

Referenciando la tabla 12, el sujeto 2 tuvo un porcentaje de calificación promedio de 71.4%.

	Clase Resultado (Nada)	Clase Resultado (Flexión)
Clase Objetivo (Nada)	0.55	0.45
Clase Objetivo (Flexión)	0.12	0.88

**Tabla 12:** Movimiento Real, Sujeto 2, Segunda Sesión

Referenciando la tabla 13, el sujeto 2 tuvo un porcentaje de calificación promedio de 72.4%.

	Clase Resultado (Nada)	Clase Resultado (Flexión)
Clase Objetivo (Nada)	0.72	0.28
Clase Objetivo (Flexión)	0.28	0.72

**Tabla 13:** Movimiento Real, Sujeto 2, Tercera Sesión

#### ○ **Movimiento Imaginado**

Referenciando la tabla 14, el sujeto 2 tuvo un porcentaje de calificación promedio de 67.6%.

	Clase Resultado (Nada)	Clase Resultado (Flexión)
Clase Objetivo (Nada)	0.52	0.48

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

Clase Objetivo (Flexión)	0.16	0.84
--------------------------	------	------

**Tabla 14:** Movimiento Imaginado, Sujeto 2, Primera Sesión

Referenciando la tabla 15, el sujeto 2 tuvo un porcentaje de calificación promedio de 58.8%.

	Clase Resultado (Nada)	Clase Resultado (Flexión)
Clase Objetivo (Nada)	0.58	0.42
Clase Objetivo (Flexión)	0.40	0.60

**Tabla 15:** Movimiento Imaginado, Sujeto 2, Segunda Sesión

Referenciando la tabla 16, el sujeto 2 tuvo un porcentaje de calificación promedio de 60.4%.

	Clase Resultado (Nada)	Clase Resultado (Flexión)
Clase Objetivo (Nada)	0.61	0.39
Clase Objetivo (Flexión)	0.40	0.60

**Tabla 16:** Movimiento Imaginado, Sujeto 2, Tercera Sesión

### 3.1.3 Sujeto 3

#### ○ Movimiento Real

Referenciando la tabla 17, el sujeto 3 tuvo un porcentaje de calificación promedio de 88%.

	Clase Resultado (Nada)	Clase Resultado (Flexión)
Clase Objetivo (Nada)	0.96	0.04
Clase Objetivo (Flexión)	0.20	0.8

**Tabla 17:** Movimiento Real, Sujeto 3, Primera Sesión

Referenciando la tabla 18, el sujeto 3 tuvo un porcentaje de calificación promedio de 73.4%.

	Clase Resultado (Nada)	Clase Resultado (Flexión)
Clase Objetivo (Nada)	0.80	0.20
Clase Objetivo (Flexión)	0.33	0.67

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.



**Tabla 18:** Movimiento Real, Sujeto 3, Segunda Sesión

Referenciando la tabla 19, el sujeto 3 tuvo un porcentaje de calificación promedio de 85.2%.

	Clase Resultado (Nada)	Clase Resultado (Flexión)
Clase Objetivo (Nada)	0.96	0.04
Clase Objetivo (Flexión)	0.25	0.75

**Tabla 19:** Movimiento Real, Sujeto 3, Tercera Sesión

○ **Movimiento Imaginado**

Referenciando la tabla 20, el sujeto 3 tuvo un porcentaje de calificación promedio de 72.2%.

	Clase Resultado (Nada)	Clase Resultado (Flexión)
Clase Objetivo (Nada)	0.74	0.26
Clase Objetivo (Flexión)	0.30	0.70

**Tabla 20:** Movimiento Imaginado, Sujeto 3, Primera Sesión

Referenciando la tabla 21, el sujeto 3 tuvo un porcentaje de calificación promedio de 73.4%.

	Clase Resultado (Nada)	Clase Resultado (Flexión)
Clase Objetivo (Nada)	0.74	0.26
Clase Objetivo (Flexión)	0.27	0.73

**Tabla 21:** Movimiento Imaginado, Sujeto 3, Segunda Sesión

Referenciando la tabla 22, el sujeto 3 tuvo un porcentaje de calificación promedio de 64%.

	Clase Resultado (Nada)	Clase Resultado (Flexión)
Clase Objetivo (Nada)	0.61	0.39
Clase Objetivo (Flexión)	0.33	0.67

**Tabla 22:** Movimiento Imaginado, Sujeto 3, Tercera Sesión

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

### 3.1.4 Sujeto 4

#### ○ Movimiento Real

Referenciando la tabla 23, el sujeto 4 tuvo un porcentaje de calificación promedio de 85.2%.

	Clase Resultado (Nada)	Clase Resultado (Flexión)
Clase Objetivo (Nada)	0.92	0.08
Clase Objetivo (Flexión)	0.22	0.78

**Tabla 23:** Movimiento Real, Sujeto 4, Primera Sesión

Referenciando la tabla 24, el sujeto 4 tuvo un porcentaje de calificación promedio de 91.4%.

	Clase Resultado (Nada)	Clase Resultado (Flexión)
Clase Objetivo (Nada)	1.00	0.00
Clase Objetivo (Flexión)	0.17	0.83

**Tabla 24:** Movimiento Real, Sujeto 4, Segunda Sesión

Referenciando la tabla 25, el sujeto 4 tuvo un porcentaje de calificación promedio de 87.4%.

	Clase Resultado (Nada)	Clase Resultado (Flexión)
Clase Objetivo (Nada)	1.00	0.00
Clase Objetivo (Flexión)	0.25	0.75

**Tabla 25:** Movimiento Real, Sujeto 4, Tercera Sesión

#### ○ Movimiento Imaginado

Referenciando la tabla 26, el sujeto 4 tuvo un porcentaje de calificación promedio de 76.1%.

	Clase Resultado (Nada)	Clase Resultado (Flexión)
Clase Objetivo (Nada)	0.78	0.22
Clase Objetivo (Flexión)	0.26	0.74

**Tabla 26:** Movimiento Imaginado, Sujeto 4, Primera Sesión

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

Referenciando la tabla 27, el sujeto 4 tuvo un porcentaje de calificación promedio de 66.2%.

	Clase Resultado (Nada)	Clase Resultado (Flexión)
Clase Objetivo (Nada)	0.55	0.45
Clase Objetivo (Flexión)	0.22	0.78

**Tabla 27:** Movimiento Imaginado, Sujeto 4, Segunda Sesión

Referenciando la tabla 28, el sujeto 4 tuvo un porcentaje de calificación promedio de 50%.

	Clase Resultado (Nada)	Clase Resultado (Flexión)
Clase Objetivo (Nada)	0.78	0.22
Clase Objetivo (Flexión)	0.78	0.22


**Tabla 28:** Movimiento Imaginado, Sujeto 4, Tercera Sesión

### 3.2 SESIONES ONLINE

Como se mencionó antes, hubo ciertas discrepancias en los datos obtenidos para algunos de los sujetos de investigación. Con el fin de disminuirlas al máximo, se habló con el Profesor Robinson Alberto Torres para ver si era posible llevar a cabo la toma de datos en algún lugar con menos ruido electromagnético y con menos personas, para que estas no fueran una distracción durante la toma de datos. De esta manera, se obtuvo la autorización para hacer las pruebas online en un salón de clase vacío de la Universidad EIA, sede Zúñiga. Se hizo nuevamente un par de sesiones offline (una sesión de movimiento real y una sesión de movimiento imaginado) antes de hacer la prueba online para poder entrenar los filtros y los clasificadores en estas nuevas condiciones de medición.

A continuación, se mostrarán los resultados obtenidos para cada sujeto de investigación junto con sus respectivas matrices de confusión. Nuevamente es posible evidenciar que las sesiones en las que era necesario llevar a cabo el movimiento, se obtenía un valor de clasificación más alto. Las pruebas online de todos los participantes tuvieron que ser finalmente interrumpidas ya que la precisión del clasificador no era lo suficiente alta, ocasionando que las contracciones involuntarias del musculo eventualmente se volvieran molestas para los participantes. La figura 43 muestra a uno de los sujetos de investigación logrando controlar la contracción de su brazo usando la señal de EEG antes de decidir parar.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.



**Figura 43:** Contracción controlada por señal EEG

### 3.2.1 Sujeto 1

#### ○ **Movimiento Real**

Referenciando la tabla 35, el sujeto 1 tuvo un porcentaje de calificación promedio de 68.8%.

	Clase Resultado (Nada)	Clase Resultado (Flexión)
Clase Objetivo (Nada)	0.66	0.36
Clase Objetivo (Flexión)	0.28	0.72

**Tabla 29:** Movimiento Real, Sujeto 1

#### ○ **Movimiento Imaginado**

Referenciando la tabla 36, el sujeto 1 tuvo un porcentaje de calificación promedio de 67.4%.

	Clase Resultado (Nada)	Clase Resultado (Flexión)
Clase Objetivo (Nada)	0.65	0.35
Clase Objetivo (Flexión)	0.3	0.7

**Tabla 30:** Movimiento Imaginado, Sujeto 1

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

### 3.2.2 Sujeto 2

- **Movimiento Real**

Referenciando la tabla 37, el sujeto 2 tuvo un porcentaje de calificación promedio de 82%.

	Clase Resultado (Nada)	Clase Resultado (Flexión)
Clase Objetivo (Nada)	0.92	0.08
Clase Objetivo (Flexión)	0.28	0.72

**Tabla 31:** Movimiento Real, Sujeto 2

- **Movimiento Imaginado**

Referenciando la tabla 38, el sujeto 2 tuvo un porcentaje de calificación promedio de 61.8%.

	Clase Resultado (Nada)	Clase Resultado (Flexión)
Clase Objetivo (Nada)	0.64	0.36
Clase Objetivo (Flexión)	0.40	0.60

**Tabla 32:** Movimiento Imaginado, Sujeto 2

### 3.2.3 Sujeto 3

- **Movimiento Real**

Referenciando la tabla 39, el sujeto 3 tuvo un porcentaje de calificación promedio de 96.6%.

	Clase Resultado (Nada)	Clase Resultado (Flexión)
Clase Objetivo (Nada)	1.00	0.00
Clase Objetivo (Flexión)	0.07	0.93

**Tabla 33:** Movimiento Real, Sujeto 3

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

○ **Movimiento Imaginado**

Referenciando la tabla 40, el sujeto 3 tuvo un porcentaje de calificación promedio de 61.8%.

	Clase Resultado (Nada)	Clase Resultado (Flexión)
Clase Objetivo (Nada)	0.62	0.38
Clase Objetivo (Flexión)	0.38	0.62

**Tabla 34:** Movimiento Imaginado, Sujeto 3

### 3.2.4 Sujeto 4

○ **Movimiento Real**

Referenciando la tabla 41, el sujeto 4 tuvo un porcentaje de calificación promedio de 69.6%.

	Clase Resultado (Nada)	Clase Resultado (Flexión)
Clase Objetivo (Nada)	0.75	0.25
Clase Objetivo (Flexión)	0.36	0.64

**Tabla 35:** Movimiento Real, Sujeto 4

○ **Movimiento Imaginado**

Referenciando la tabla 42, el sujeto 4 tuvo un porcentaje de calificación promedio de 58%.

	Clase Resultado (Nada)	Clase Resultado (Flexión)
Clase Objetivo (Nada)	0.69	0.31
Clase Objetivo (Flexión)	0.53	0.47

**Tabla 36:** Movimiento Imaginado, Sujeto 4

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

## **4. CONCLUSIONES Y CONSIDERACIONES FINALES**

### **4.1 CONCLUSIONES**

El alcance del presente escrito muestra ser prometedor en el ámbito de la rehabilitación médica, a pesar de que los porcentajes de clasificación fueron alrededor del 60% realizando más sesiones de entrenamiento se podrían incrementar considerablemente. No solo es útil para aquellas personas que han sufrido de accidentes cerebrovasculares, sino también para cualquier otro tipo de lesión cerebral que haya afectado la capacidad motora de la persona.

Considerando que hay equipos de EEG en el mercado de bajo costo (\$1000USD) como los que menciona Farnsworth en su artículo “EEG Headset Prices – An Overview of 15+ EEG Devices” (Farnsworth, 2019), y que hacer el circuito de FES tiene un precio de menos de 40.000 COP, sería posible reproducir el trabajo planteado en el presente escrito con menos de 3.400.000 COP. Su bajo costo facilitaría el acceso a una gran cantidad de personas que hayan sufrido de accidente cerebrovascular.

Implementando diferentes plataformas de programación (MATLAB, Python, OpenVibe) se descubrió que OpenViBE se acogía más adecuadamente a las necesidades del trabajo. Utilizando esta plataforma se desarrolló un algoritmo que filtrara y procesara las señales de EEG obtenidas de cada sujeto en tiempo real. De esta manera, fue posible clasificar dichas señales y con base a esto identificar a la imagen motora generada por el sujeto.

Estableciendo una comunicación jerárquica desde OpenVibe (programa utilizado para adquirir y procesar las señales) hacia Python (programa utilizado como mediador entre Arduino y OpenVibe) y finalmente Arduino (expresar el comando recibido como un 1 o un 0 lógico) se logró encender y apagar un LED usando las señales de EEG obtenidas. Así mismo, se probó el circuito FES usándolo en lugar del LED. Finalmente se obtuvo contracción del brazo como se esperaba utilizando el circuito FES mediante la clasificación de las señales EEG del sujeto.

La función principal que cumple el equipo de BCI/FES es facilitar el desarrollo de nuevos caminos neuronales haciendo ejercicios mentales mientras que simultáneamente se genera un estímulo visual (la barra azul que se muestra en la pantalla del computador en la figura 28) y sensorial (el circuito de electroestimulación). Es por esto por lo que las funciones motoras afectadas por la lesión cerebral pueden ser eventualmente acogidas por otras partes del cerebro si se lleva a cabo un entrenamiento adecuado como el que se propone en este proyecto. Además, es algo que se puede aplicar para otras extremidades.

### **4.2 CONSIDERACIONES FINALES**

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

- **Jaula de Faraday:** Las señales de EEG suelen ser del orden de unos cientos de  $\mu V$ . Esto implica que pueden ser contaminadas con facilidad por cualquier otra señal electromagnética de mayor amplitud. Normalmente esto se puede solucionar mediante el uso de filtros digitales y analógicos. Sin embargo, existirá siempre una imitación de hasta qué punto se puede filtrar una señal sin perder información significativa. Usando una jaula de Faraday sería posible aislar el ruido electromagnético exterior para poder asegurar una mejor calidad de las señales. Según Chandler, una jaula de Faraday es capaz de tomar la radiación electromagnética del exterior de la jaula y distribuirla a través de su superficie, cancelando de esta manera las cargas eléctricas de su interior (Chandler, 2011).
- Al igual que otros ejercicios mentales, modular una señal específica del cerebro es algo que requiere de práctica. Es por esta razón que se recomienda a aquellos que vayan a hacer investigaciones futuras en el tema, llevar a cabo una mayor cantidad de sesiones de entrenamiento con los participantes. Considerando que la fatiga mental puede igualmente afectar la calidad de la señal, se cree que lo ideal sería hacer alrededor de 6 sesiones cortas durante varios días hasta lograr un porcentaje de clasificación adecuado.
- **Ensayar otros programas.** El presente escrito se basó principalmente en el uso del programa OpenVibe. Sin embargo, tras hablar con estudiantes que han hecho mediciones de otros biopotenciales con el g.USBamp usando LABVIEW, se considera que valdría la pena indagar en futuras investigaciones que tan bien funciona LABVIEW para procesar y clasificar señales de EEG en tiempo real.
- **Investigar de cuales otros grupos musculares es posible generar una imagen motora reconocible mediante EEG.** Hasta ahora lo más fácil es generalizar de la pierna o el brazo como una sola imagen motora, pero para grupos musculares tan grandes como las piernas y los brazos sería posible generar más de una sola imagen motora. Sería interesante ver hasta qué punto se pueden distinguir movimientos imaginados más finos y centralizados dentro de unos grupos tan macro como las piernas y los brazos. Sin embargo, es importante tener en cuenta que, para identificar movimientos motrices finos, como el de los dedos de la mano mediante EEG, puede dificultarse mucho por la amplitud de la onda.



## REFERENCIAS

- Hatem, S. M., Saussez, G., Della Faille, M., Prist, V., Zhang, X., Dispa, D., & Bleyenheuft, Y. (2016). Rehabilitation of Motor Function after Stroke: A Multiple Systematic Review Focused on Techniques to Stimulate Upper Extremity Recovery. *Frontiers in human neuroscience*, 10, 442. doi:10.3389/fnhum.2016.00442
- Takeda, K., Tanino, G., & Miyasaka, H. (2017). Review of devices used in neuromuscular electrical stimulation for stroke rehabilitation. *Medical devices (Auckland, N.Z.)*, 10, 207-213. doi:10.2147/MDER.S123464
- She, Qingshan & Hu, Bo & Luo, Zhizeng & Nguyen, Thinh & Zhang, Yingchun. (2018). A hierarchical semi-supervised extreme learning machine method for EEG recognition. *Medical & Biological Engineering & Computing*. 1-11. 10.1007/s11517-018-1875-3.
- Olivas, Brenda E & Chacon, Mario. (2018). Classification of multiple motor imagery using deep convolutional neural networks and spatial filters. *Applied Soft Computing*. 75. 10.1016/j.asoc.2018.11.031.
- Dose, Hauke & S. Møller, Jakob & Iversen, Helle & Puthusserypady, Sadasivan. (2018). An end-to-end deep learning approach to MI-EEG signal classification for BCIs. *Expert Systems with Applications*. 114. 10.1016/j.eswa.2018.08.031
- Jo, Sungho & Woo Choi, Jin. (2018). Effective motor imagery training with visual feedback for non-invasive brain computer interface. 1-4. 10.1109/IWW-BCI.2018.8311524
- Alonso-Valerdi, Luz & Salido-Ruiz, Ricardo & Ramírez-Mendoza, Ricardo A.. (2015). Motor Imagery based Brain-Computer Interfaces: An Emerging Technology to Rehabilitate Motor Deficits. *Neuropsychologia*. 10.1016/j.neuropsychologia.2015.09.012
- Jure, Fabricio & Carrere, Lucia & Gentiletti, Gerardo & Tabernig, Carolina. (2015). BCI-FES System for Neuro-rehabilitation of Stroke Patients
- Ang, Kai & Guan, Cuntai. (2015). Brain-Computer Interface for Neurorehabilitation of Upper Limb After Stroke. *Proceedings of the IEEE*. 103. 944-953. 10.1109/JPROC.2015.2415800
- Sundar, Aditya & Das, Chinmay. (2015). MATLAB analysis of EEG signals for diagnosis of epileptic seizures. 10.13140/RG.2.1.1367.4088
- Delorme, Arnaud & Kothe, Christian & Vankov, Andre & Bigdely-Shamlo, Nima & Oostenveld, Robert & Zander, Thorsten & Makeig, Scott. (2010). MATLAB-based tools for BCI research. 10.1007/978-1-84996-272-8\_14
- Feigin, V. L., Krishnamurthi, R. V., Parmar, P., Norrving, B., Mensah, G. A., Bennett, D. A., ... Roth, G. A. (2015). Update on the Global Burden of Ischemic and Hemorrhagic Stroke in 1990-2013: The GBD 2013 Study. *Neuroepidemiology*, 45(3), 161-176. <https://doi.org/10.1159/000441085>

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

Costa, A. P., Møller, J. S., Iversen, H. K., & Puthusserypady, S. (2018). An adaptive CSP filter to investigate user independence in a 3-class MI-BCI paradigm. *Computers in Biology and Medicine*, 103, 24-33. DOI: 10.1016/j.combiomed.2018.09.021

Zapała, D., Francuz, P., Zapała, E., Kopiś, N., Wierzgała, P., Augustynowicz, P., Majkowski, A., & Kołodziej, M. (2018). The Impact of Different Visual Feedbacks in User Training on Motor Imagery Control in BCI. *Applied psychophysiology and biofeedback*.

Ramoser, H., Müller-Gerking, J., & Pfurtscheller, G. (2000). Optimal spatial filtering of single trial EEG during imagined hand movement. *IEEE transactions on rehabilitation engineering: a publication of the IEEE Engineering in Medicine and Biology Society*, 8 4, 441-6

Dobkin B. H. (2005). Clinical practice. Rehabilitation after stroke. *The New England journal of medicine*, 352(16), 1677-84

Kandel, E. R., Schwartz, J. H., & Jessell, T. M. (2000). *Principles of neural science*. New York: McGraw-Hill, Health Professions Division

Herrero, Azael & Abadía García de Vicuña, Olaia & Morante Rábago, Juan & Garcia-Lopez, Juan. (2006). Parámetros de entrenamiento con electroestimulación y efectos crónicos sobre la función muscular (I). *Archivos de Medicina del Deporte*.

Morshed, B.I., & Khan, A. (2014). A Brief Review of Brain Signal Monitoring Technologies for BCI Applications: Challenges and Prospects.

Sarma, P.M., Tripathi, P.S., Sarma, M.P., & Sarma, K.K. (2016). Pre-processing and Feature Extraction Techniques for EEGBCI Applications- A Review of Recent Research.

Mallick, A., Kapgate, D. (2015) A review on signal pre-processing techniques in brain computer interface. *Int J Comput Technol* 2(4):130–134

Lotte, Fabien & Guan, Cuntai. (2011). Regularizing Common Spatial Patterns to Improve BCI Designs: Unified Theory and New Algorithms. *Biomedical Engineering, IEEE Transactions on*. 58. 355 - 362. 10.1109/TBME.2010.2082539

Saleh, A.I., Shehata, S.A. & Labeeb, L.M. (2019) A fuzzy-based classification strategy (FBCS) based on brain–computer interface. <https://doi.org/10.1007/s00500-017-2930-y>

Johnson, W., Onuma, O., Owolabi, M., & Sachdev, S. (2016). Stroke: A global response is needed. *Bulletin of the World Health Organization*. 94. 634-634A. 10.2471/BLT.16.181636.

Rossini, Paolo & A. Noris Ferilli, M & Ferreri, Florinda. (2012). Cortical plasticity and brain computer interface. *European journal of physical and rehabilitation medicine*. 48. 307-12

Yuan, H., & He, B. (2014). Brain-computer interfaces using sensorimotor rhythms: current state and future perspectives. *IEEE transactions on bio-medical engineering*, 61(5), 1425–1435. doi:10.1109/TBME.2014.2312397

Wolpaw, Jonathan & Birbaumer, N & Heetderks, W.J. & Mcfarland, Dennis & Hunter Peckham, P & Schalk, Gerwin & Donchin, Emanuel & Quatrano, L.A. & Robinson, Charles & Vaughan, Theresa.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

(2000). Brain-Computer interface technology: A review of the first international meeting. IEEE transactions on rehabilitation engineering: a publication of the IEEE Engineering in Medicine and Biology Society. 8. 164-73. 10.1109/TRE.2000.847807.

Vidal, J.J. (1973). Toward direct brain-computer communication. Annual review of biophysics and bioengineering, 2, 157-80

Brunner, C., Leeb, R., Müller-Putz, G., Schlögl, A., & Pfurtscheller, G. (2008). BCI Competition 2008–Graz data set A. Institute for Knowledge Discovery (Laboratory of Brain-Computer Interfaces), Graz University of Technology, 16

BCI Competition IV (2019). BCI Competition IV: Results. Extraído de: <http://www.bbci.de/competition/iv/results/index.html#dataset2a>

Gramfort, Alexandre & Luessi, Martin & Larson, Eric & A Engemann, Denis & Strohmeier, Daniel & Brodbeck, Christian & Goj, Roman & Jas, Mainak & Brooks, Teon & Parkkonen, Lauri & Hämäläinen, Matti. (2013). MEG and EEG data analysis with MNE-python. Frontiers in neuroscience. 7. 267. 10.3389/fnins.2013.00267.

Renard, Y., Lotte, F., Gibert, G., Congedo, M., Maby, E., Delannoy, V., Bertrand, O., & Lécuyer, A. (2010). OpenViBE: An Open-Source Software Platform to Design, Test, and Use BrainComputer Interfaces in Real and Virtual Environments. PRESENCE: Teleoperators and Virtual Environments, 19, 35-53

Barachant, A. & Jayaram, V. (2018). MOAB: Mother of all BCI benchmark. Extraído de: <http://moabb.neurotechx.com/docs/index.html>

Popovic, D.B. (2014). Advances in functional electrical stimulation (FES). Journal of electromyography and kinesiology: official journal of the International Society of Electrophysiological Kinesiology, 24 6, 795-802.

Basas García, A. (2001). Metodología de la electroestimulación en el deporte. Fisioterapia. 23. 36–47. 10.1016/S0211-5638(01)72971-9.

Mejía Jaramillo, M.C. (2017) Sistema de electroestimulación y electromiografía para hospitalización (Trabajo de grado). Universidad EIA. Recuperado de: <http://repository.eia.edu.co/handle/11190/1979>

Yan, Tiebin & W Y Hui-Chan, Christina & Li, Leonard. (2005). Functional Electrical Stimulation Improves Motor Recovery of the Lower Extremity and Walking Ability of Subjects With First Acute Stroke: A Randomized Placebo-Controlled Trial. Stroke; a journal of cerebral circulation. 36. 80-5. 10.1161/01.STR.0000149623.24906.63.

Teo, W., & Chew, E. (2014). Is motor-imagery brain-computer interface feasible in stroke rehabilitation? PM & R : the journal of injury, function, and rehabilitation, 6 8, 723-8 .

Manske, Robert & Magee, David & Zachazewski, James & Quillen, William. (2016). Pathology and Intervention in Musculoskeletal Rehabilitation (Second Edition). 2. 25-62. 10.1016/B978-0-323-31072-7.00002-6.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

Cohen, R. (2014). New Open Source Platform Allows Anyone To Hack Brain Waves. Extraído de: <https://www.forbes.com/sites/reuvencohen/2014/01/03/new-open-source-platform-allows-anyone-to-hack-brain-waves/#7aa1c38f1b3f>

Farnsworth, B. (2019). EEG Headset Prices – An Overview of 15+ EEG Devices. Extraído de: <https://imotions.com/blog/eeeg-headset-prices/>

Gurumurthy, S., Mahit, V. S., & Ghosh, R. (2013). Analysis and simulation of brain signal data by EEG signal processing technique using MATLAB. Extraído de: <https://pdfs.semanticscholar.org/e871/54c2803a28288925fc46c67e004e1ee12989.pdf>

López, D. M., & Pabón, M. C. (2013). Sistema de Reconocimiento de Patrones de Potenciales Evocados Visuales de Estado Estacionario (Tesis de Pregrado). Escuela de Ingeniería de Antioquia - Universidad CES.

Nilsson, J. W., & Riedel, S. A (2005). Circuitos Eléctricos (Séptima edición). Pearson Education. ISBN: 9788420544588.

Fisher, R., Perkins, S., Walker, A. & Wolfart, E. (2000). Laplacian/Laplacian of Gaussian. Extraído de: <https://homepages.inf.ed.ac.uk/rbf/HIPR2/log.htm>

Raschka, S. (Octubre 10, 2019). Linear Discriminant Analysis. Extraído de: [http://sebastianraschka.com/Articles/2014\\_python\\_lda.html](http://sebastianraschka.com/Articles/2014_python_lda.html).

Li, C., & Wang, B. (2014). Fisher Linear Discriminant Analysis. Extraído de: <https://pdfs.semanticscholar.org/1ab8/ea71fbef3b55b69e142897fadf43b3269463.pdf>

Arduino (s.f) EEPROM Clear. Extraído de: <https://www.arduino.cc/en/Tutorial/EEPROMClear>

Chandler, N. (2011, 28 de junio). How Faraday Cages Work. Extraído de: <https://science.howstuffworks.com/faraday-cage.htm>

TBI Rehabilitation (2018). Different Types of Brain Waves: Delta, Theta, Alpha, Beta, Gamma. Extraído de: <https://tbirehabilitation.wordpress.com/2018/09/28/web-site-different-types-of-brain-waves-delta-theta-alpha-beta-gamma/>

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.

La información presentada en este documento es de exclusiva responsabilidad de los autores y no compromete a la EIA.